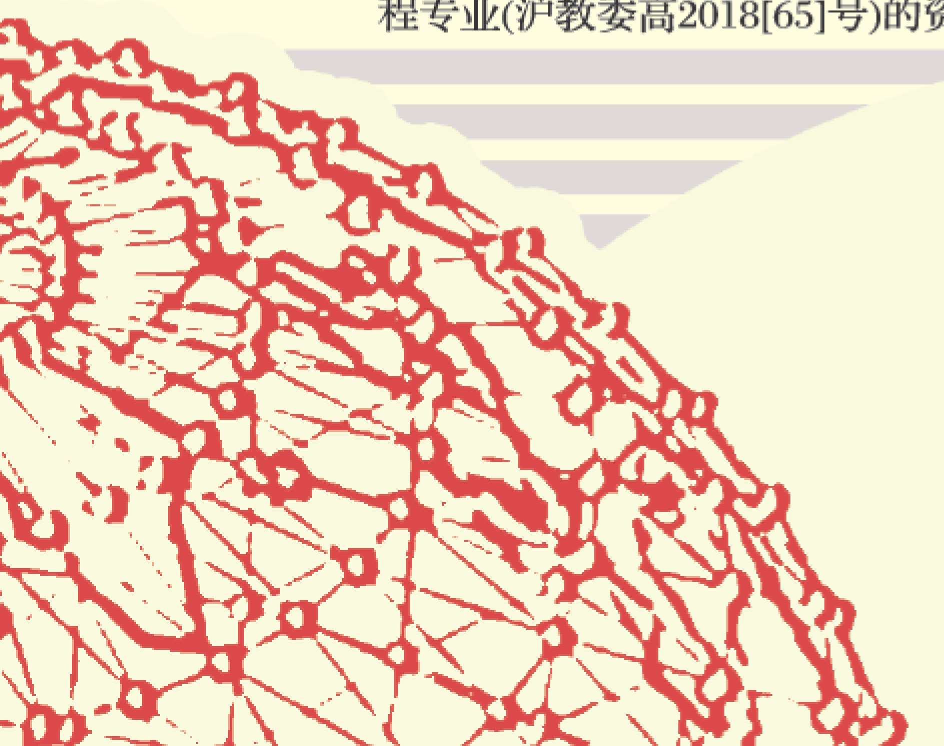
本书得到了国家自然科学基金重点项目（项目编号：71632008）、国家自然科学基金项目（项目编号：71371123）、教育部人文社会科学研究青年基金项目（项目编号：15YJCZH096）、第六批上海市属高校应用型本科试点专业建设项目上海理工大学工业工程专业(沪教委高2018[65]号)的资助。





大数据驱动的设备健康预测及维护决策优化



董　明　刘勤明◎著

清華大學出版社

清华汇智文库

大数据驱动的设备健康预测及维护决策优化

董明　刘勤明　著

清华大学出版社
北京

内 容 简 介

本书是近几年作者对设备健康预测及维护领域的研究成果及经验总结，可以作为管理科学与工程、工业工程等专业研究生科研辅助资料，使其了解设备的运行状态、衰退趋势以及采取的维护策略。本书共分五个专题：国内外相关研究述评，单监测信息的在线健康预测，多监测信息的在线健康预测，设备集成动态维护，设备维护调度。每一个专题都有引言部分和小结部分，通过引言的学习，研究生可以掌握本专题的基本观点、原理和模型方法；通过小结的学习，研究生对本专题有一个全面的认知和应用。

图书在版编目（CIP）数据

大数据驱动的设备健康预测及维护决策优化/董明，刘勤明著．—北京：清华大学出版社，2019
（清华汇智文库）
ISBN 978-7-302-49632-8

Ⅰ.①大… Ⅱ.①董… ②刘… Ⅲ.①数据管理—设备管理 Ⅳ.①TP274

中国版本图书馆 CIP 数据核字(2018)第 031755 号

责任编辑： 杜 星
封面设计： 汉风唐韵
责任校对： 宋玉莲
责任印制： 沈 露

出版发行： 清华大学出版社
网 址： http://www.tup.com.cn，http://www.wqbook.com
地 址： 北京清华大学学研大厦 A 座 **邮 编：** 100084
社 总 机： 010-62770175 **邮 购：** 010-62786544
投稿与读者服务： 010-62776969，c-service@tup.tsinghua.edu.cn
质量反馈： 010-62772015，zhiliang@tup.tsinghua.edu.cn
印 装 者： 三河市吉祥印务有限公司
经 销： 全国新华书店
开 本： 170mm×230mm **印 张：** 12.5 **插 页：** 1 **字 数：** 232 千字
版 次： 2019 年 1 月第 1 版 **印 次：** 2019 年 1 月第1 次印刷
印 数：
定 价： 98.00 元

产品编号：078227-01

前 言

Foreword

随着现代信息技术、物联网及大数据的快速发展，数据驱动的设备健康预测、维护及运行状态，对企业生产经营和经济效益的影响也日益显著。设备的可靠性和有效维护保障了企业正常运行，是企业生存的必要条件。因此，高效的设备维护在企业生产经营中的作用和地位日益突出，是企业降低生产成本和保证生产效率的基础。半个多世纪以来，不少学者针对设备的维护进行了许多研究，但是，设备健康预测对维护策略影响方面的研究较少。

本书立足于过去几十年国内外的设备健康预测与维护相关的研究基础，利用数据分析了设备的运行状态，描述了设备的衰退趋势，实现了有效的在线健康预测，为设备的集成动态维护提供了决策依据。首先，本书应用隐式半马尔可夫模型(Hidden semi-Markov-Model，HSMM)对设备在线运行过程中的健康进行识别与预测，提出了单监测信息在线健康预测方法。其次，基于单监测信息在线健康预测，探讨了多监测信息的在线健康预测方法。再次，基于设备在线健康预测和衰退性能的预测，建立了设备的集成动态维护模型，从而有助于设备维护领域的发展。最后，基于集成维护模型，描述了多部件设备维护调度的优化。

第 1 章是绪论部分，这部分主要阐述本书选题的背景、研究的技术路线，并且讨论了研究主要创新点和所期望达到的研究目标。

第 2 章是相关概念部分，描述了设备健康管理的发展历程，分析和探讨了已有设备健康预测、设备维护及调度的相关研究，包括对已有的研究进行回顾，评论已有方法的不足，确定需要进一步研究的方向。同时，给出了退化隐半马尔可夫模型的概念。

第 3 章研究了单监测信息的在线健康预测问题。基于 HSMM 和序列蒙特卡

洛(Sequential Monte Carlo，SMC)的联合优化，建立了一套完整的 HSMM 和 SMC 联合优化的在线健康预测模型，提出了一种联合多步向前健康识别算法，用于在线识别设备的健康状态，并且，建立了在线剩余寿命预测模型。目前，已有的单一方法、模型、算法很难满足设备的在线健康预测，本研究提出的联合模型，基于 HSMM 丰富的数学结构和 SMC 的在线特征，利用设备的健康预测对其性能状态进行量化，进而描述了设备的实际运行状况，为设备在线健康管理提供理论支持和决策依据。

第 4 章在单监测信息健康预测的基础上，建立了多监测信息的在线健康预测模型。为了更好地提高在线健康预测的精确度，基于单监测信息在线健康预测方法的思想，本书提出了多监测信息的在线健康预测方法。为了处理多监测信息和降低模型的计算复杂性，对 HSMM 的基本算法进行了修正，计算复杂性从 $O[(MD+M^2)T]$ 降低到 $O[(D+M^2)T]$。建立了自适应隐式半马尔可夫模型(Adaptive Hidden semi-Markov Model，AHSMM)，来处理多监测信息的在线健康预测问题，应用最大似然线性回归训练对输出概率分布和驻留概率分布进行自适应训练，处理多监测信息之间的差异性。结合修正的 HSMM 进行有效的多监测信息在线健康预测。在此基础上，本书提出了多监测信息的在线剩余寿命预测方法。同时，探讨了设备的在线健康管理，得到基于多监测信息的预测模型，并比较了两种健康预测方式的异同，给出了多源信息融合健康管理的启示与思考。

第 5 章在设备健康预测基础上，建立了基于在线健康预测的集成动态维护模型。不同于传统的维护方式，集成维护将设备的退化信息和老化信息引入维护模型中，结合设备的诊断信息和预测信息，以总的维护成本(故障成本、维护成本和资源成本)和总维护时间为目标，建立了两层集成动态维护模型。在传统的维护模型中，设备的维护资源只考虑了备件的约束条件，而本书同时考虑了备件和维修人员的双约束条件。另外，针对小修和大修的维护方式，引入了维护风险因素，将维护风险因子集成到维护模型，提出了设备集成维护管理的建议和策略。

第 6 章在系统的维护策略的基础上，建立了基于集成维护模型的维护调度优化模型，针对多部件设备的特点，建立了多部件设备的维护拓展模型。多部件设备的维护决策包括性能衰退、维护方式和维护费用三部分。在性能衰退方面，通过在线诊断信息和预测信息得到设备故障率的变化趋势，用威布尔分布模拟设备的衰退过程；在维护方式方面，定义小修、大修和更换三种维护方式，分别描述了三种维护方式对设备故障率的影响；在维护费用方面，考虑了故障成本、维护成本、资源成

本和停机成本四部分，根据每次维护活动的费用模型，建立了多阶段的总费用率模型。本研究为多部件设备维护管理奠定了理论基础和决策依据。

第 7 章为研究工作的总结，给出了研究的结论，并讨论了多源状态信息下的设备在线健康预测、集成维护与设备衰退问题未来可能的研究方向。

本书的 7 章内容相互之间联系紧密，形成了一个数据驱动的系统性设备维护决策框架。基于单监测信息在线健康预测思想，提出了多监测信息的健康预测方法；基于在线健康预测，提出了考虑设备衰退性能和维护资源的集成动态维护模型。本书所做的研究内容有助于提高企业的维护水平和设备可靠性、降低维护成本、提高设备利用率，最终提高企业的竞争力。同时，拓展了制造系统的维护管理领域，为制造企业维护策略的制定提供决策支持和科学有效的指导。

本书得到了国家自然科学基金重点项目（项目编号：71632008）、国家自然科学基金项目（项目编号：71371123）、教育部人文社会科学研究青年基金项目（项目编号：15YJCZH096）的资助，笔者深表谢意。由于笔者的水平有限，书中难免有不妥之处，敬请读者不吝批评指正。

董　明　上海交通大学
刘勤明　上海理工大学
2018-05-20

目 录

Contents

第 1 章　绪　论 …… 1
1.1　研究背景和意义 …… 1
1.2　研究范围与对象 …… 4
1.3　研究目的与创新点 …… 5
1.4　研究框架 …… 7
1.5　本章小结 …… 8
第 2 章　设备维护的概念 …… 9
2.1　引言 …… 9
2.2　设备健康管理的历史发展 …… 12
2.3　设备健康预测方法的研究及进展 …… 14
2.3.1　基于物理模型的方法 …… 15
2.3.2　基于知识驱动的方法 …… 17
2.3.3　基于数据驱动的方法 …… 20
2.3.4　基于模型驱动的方法 …… 26
2.3.5　基于信息融合的方法 …… 31
2.3.6　混合模型 …… 32
2.4　设备维护方法的研究及进展 …… 36
2.4.1　基于健康信息的维护 …… 38
2.4.2　基于衰退过程的维护 …… 40
2.4.3　基于备件库存的维护 …… 41
2.5　设备维护调度方法的研究及进展 …… 42
2.6　现有方法的不足 …… 47
2.6.1　设备健康预测研究的不足 …… 47

2.6.2 设备维护研究的不足 …… 48
2.6.3 设备维护调度优化需要研究的问题 …… 48
2.7 退化隐半马尔可夫模型 …… 49
2.8 本章小结 …… 56
第3章 单监测信息的在线健康预测 …… 60
3.1 引言 …… 60
3.2 设备在线健康预测方法 …… 62
3.2.1 数据预处理及特征提取 …… 62
3.2.2 在线健康预测算法 …… 64
3.2.3 剩余有效寿命预测方法 …… 68
3.3 算例分析 …… 69
3.3.1 基于 HSMM 的健康诊断 …… 71
3.3.2 数据准备与处理 …… 73
3.3.3 模型参数估计 …… 77
3.3.4 在线健康预测分析 …… 78
3.3.5 预测性能评估 …… 82
3.4 本章小结 …… 85
第4章 多监测信息的在线健康预测 …… 86
4.1 引言 …… 86
4.2 特征空间降维 …… 87
4.3 设备在线健康预测方法 …… 88
4.3.1 修正隐式半马尔可夫模型 …… 88
4.3.2 自适应隐式半马尔可夫模型 …… 92
4.3.3 剩余有效寿命预测方法 …… 94
4.4 算例分析 …… 97
4.4.1 数据准备 …… 97
4.4.2 在线健康状态识别分析 …… 98
4.4.3 在线健康预测分析 …… 101
4.4.4 预测性能评估 …… 103
4.5 本章小结 …… 106
第5章 基于在线健康预测的集成动态维护研究 …… 107
5.1 引言 …… 107

5.2 衰退过程分析 …… 112
5.3 维护动作与维护时间分析 …… 114
5.4 集成动态维护模型 …… 117
5.4.1 基本假设和符号 …… 117
5.4.2 维护成本分析 …… 119
5.4.3 基于动态规划算法维护策略优化模型 …… 123
5.4.4 维护策略优化算法 …… 127
5.5 算例分析 …… 129
5.5.1 数据准备 …… 129
5.5.2 其他维护策略 …… 133
5.5.3 维护结果分析 …… 134
5.5.4 备件库存策略分析 …… 137
5.5.5 策略动态性分析 …… 138
5.6 本章小结 …… 141
第6章 基于集成维护模型的维护调度优化研究 …… 143
6.1 引言 …… 143
6.2 设备维护调度优化模型 …… 144
6.2.1 设备维护调度决策 …… 144
6.2.2 遗传算法 …… 151
6.3 案例分析 …… 153
6.3.1 数据准备 …… 154
6.3.2 算法设计 …… 157
6.3.3 维护调度比较分析 …… 157
6.3.4 考虑调整因子的维护调度分析 …… 163
6.4 本章小结 …… 165
第7章 总结与展望 …… 166
7.1 结论 …… 166
7.2 展望 …… 168
参考文献 …… 170



1.1 研究背景和意义

当前，随着经济与科学技术的飞速发展，对设备的高可靠性要求日益增加，企业的生产需求也急剧增加，因而也提高了企业对生产设备管理的要求。企业在满足其最高产能的前提下，要求实现生产管理的高有效性、可靠性，低生产风险性及高生产安全性。在企业的生产管理中，设备管理是其一个重要的组成部分，设备管理的水平及可靠性会影响企业的持续发展、生产水平及其生产效率等。设备故障的意外发生，通常会增加企业的设备维护支出，因为在绝大多数正常情况下，设备发生故障导致的事后维修支出相较日常设备的预防性维护支出而言，要高出许多。除去维修费用，设备故障造成的计划外停机也会造成生产及与生产相关的一系列损失，使企业蒙受巨大的损失。据调查，未纳入计划的一天停工，其经济损失可高达 10 万～20 万欧元[1]。

设备是企业进行正常生产运转的技术基础，如果设备在生产使用过程中，未进行有效的维护，就可能会失效或者发生故障，对企业来说，这不仅会增加相应的设备维护成本，影响企业的生产效率，还会降低生产线上的在制品质量，从而造成企

业的巨大损失。对企业来说，由于低效或者无效的维护，维护费用的三分之一或者二分之一都浪费了[2]。因而，通过对设备进行合理有效的维护来降低故障发生率，已成为企业降低生产成本、提高生产效率和市场竞争力的重要手段之一。

工业设备和生产系统操作的可靠性对生产型企业的盈利能力和竞争能力都有重要影响，这使企业对工业生产过程和生产设备维护策略重要性的关注日益增加。维护，是指为了保持或恢复设备系统处于正常执行预定功能状态，而进行的所有相关技术和管理活动。维护最基本的作用是延长设备的使用寿命，避免事故的发生和技术性灾难，为生产节约、节省原材料和动力资源从而减少生产费用，提高生产利润和投资回报率[2]。对企业生产管理而言，制定一个行之有效的维护管理系统是非常必要的。它可以将维护成本维持在一个较低水平，同时使所有的设备都保持高效率的运作。近年来，随着设备维护研究的不断深入，以及实践的实施验证，企业管理人员和研究人员对维护管理领域的认知也在逐步提高，新的维护理念与方法、新的应用领域都不断出现[3]，主要表现如下。

(1)第三方运营维护的出现，外部社会化维护资源的介入使工业制造型企业不再依赖企业内部提供的维护资源。

(2)维护不再是一种单纯消耗企业资源的活动，而被看作是创造企业利润的来源。优化的维修策略可直接作用于生产率的提高上，从而为企业创造更多利润。

(3)设备维护管理不再只关注设备故障本身，还将与设备故障相关的许多因素，如维修后设备状态、维修成本、停工损失等，都纳入维护决策的考虑和优化的过程中。

(4)设备维护管理不再被视为孤立的管理活动单独进行，它开始与企业的其他管理职能，如库存管理、生产计划制订等相结合，共同拟订一个集成的生产维护采购计划，以取得更大的效益。

设备的主要前期维护方式包括两大类：出现故障后采取的恢复性维护方式和保持设备良好运转状态的预防性维护方式[3,4]。

其一，事后维护。表示设备出现故障后对其采取的维护方式，也就是说，设备坏了才进行维修，如果设备没有故障，就不进行维修。事后维护是一种无计划性的被动维修方式。

其二，预防维护。表示设备在生产中以预防故障为主要目的，对设备进行检查和检测，防止设备故障发生或者发现设备的故障征兆，使设备保持最初的功能状态，在故障发生之前所进行的各种维护、维修活动。

设备维护管理在经历了事后维护、预防维护阶段后，出现了一种新的设备维护方式，即状态维护（condition based maintenance，CBM）。在状态维护过程中，监测设备的工作状态及环境，通过传感器获得设备的实时状态信息，利用先进的数据处理技术对监测到的设备信息进行分析，从而获得当前的健康诊断状况，并通过一系列的设备诊断预测方法来预测设备的有效寿命，合理地确定设备的维护计划及维护时间。有效实施状态维护主要包括两个方面：诊断和预测。诊断主要表示设备出现运转异常时，对设备的故障进行诊断、判断及处理。预测主要表示设备出现故障前，对设备的状态进行预测。随着生产技术的不断发展，机械设备复杂性在提高的同时，也增加了企业生产系统的复杂性，因此，设备的诊断和预测会面临更大困难。

在新的设备维护方式中，设备的健康预测作为新兴的研究内容，被引入设备的维护研究领域，并且成为当前研究的一个热点问题。随后不久，设备的健康预测获得了蓬勃的发展，但是，在发展过程中出现的一些预测方法在使用过程中缺乏通用性，仅仅局限于某些特定的领域，如航空领域、汽车领域、国防领域等[5]，并且，已有的许多预测模型是建立在对设备的监测信息进行技术处理与分析的基础上的。在维护策略的优化研究中，对传感器检测信息的分析建模有利于设备健康预测方法的发展，促使设备在诊断当前健康状态时，还能够有效地预测未来状态的发展趋势。然而，对于目前的预测模型，大多数都是离线对设备进行健康预测，为了使预测的设备状态与设备的实际状态更加吻合，进行了单监测信息的设备在线健康预测，在此基础上，进一步研究了多监测信息的在线健康预测。在设备的维护过程中，高准确性和可靠性的设备健康预测结果是保证设备维护效果的重要因素，并影响生产安全性的提升、生产任务的合理制定、设备维护策略的有效实施、设备维护成本的降低，以及设备生产停工时间的减少等方面。虽然有效的在线健康预测是很难的研究内容，但是，设备的在线健康预测技术及方法模型仍是研究的热点领域。进行设备健康预测的意义主要体现在以下方面。

(1)从经济角度考虑，准确有效的在线健康预测可以为减少设备停机时间、提高设备的利用率、保证设备的持续使用提供基础，可以保障企业在规定的时间完成预期的工作任务，从而提高客户的满意度和企业的效益。同时，后续基于在线健康预测的设备维护，也为企业带来了合理有效的维护决策。

(2)从安全角度考虑，设备的故障或者突发故障可能会带来难以估算的安全隐患，比如航天设备、核电设备、矿山设备等，一旦发生故障，会造成人员伤亡和企业

的经济损失。如果进行合理、有效、精确的在线健康预测，就可以在设备恶化或者衰退前，对其进行合理的维护决策，从而减小设备的安全隐患。

(3)从生产角度考虑，合理有效的在线健康预测可以为企业的维护决策提供依据，可以实现用最少的备件库存满足最大的维护操作，进而降低企业的备件库存费用。

在对设备健康预测的相关模型方法进行总结归纳的基础上，本书拓展和改进了健康预测方法，提出了单监测信息和多监测信息的在线健康预测方法。基于设备监测信息的健康预测，反映了设备健康预测模型的个体特征；同时，由于设备的监测信号具有实时性，提出的在线健康预测模型不断更新，因而，实时追踪设备当前最新的健康状态可以反映设备健康预测模型的更新特征，是十分有意义的研究。

在现实中，维护不仅局限于制造业领域，也在其他行业也得到了极大的关注与应用（如服务行业），如医院里大型贵重医疗器械的维护[6]，公共设施如桥梁道路的维护[7,8]，物流行业的车辆更新[9]等对于各个行业不同的维护对象，最终的维护目标都是降低其成本，提高设备的利用率和竞争力。目前，针对设备的维护问题，设备的诊断信息发挥着重要的作用，随着对维护要求的提高，在设备的维护过程中，需要同时考虑设备的预测信息。在本书中，基于设备的在线健康预测，可获得设备的诊断信息和预测信息，对设备进行全面维护，可以满足企业的多样化需求，消除企业提高生产率的“瓶颈”问题。对基于状态监测信息的预测与系统性设备维护管理从理论和方法方面进行研究，并在此基础上实现预测性维护，可以获得巨大的经济效益。

1.2 研究范围与对象

优化的维护策略可以分为数据采集、信号处理和维护决策三个部分。数据采集表示数据收集和存储目标设备有用数据的过程；信号处理表示处理和分析数据以更好获得设备健康状态的过程；维护决策表示基于设备健康预测，制定有效维护策略的过程。维护决策包含两个基础内容：设备健康诊断与设备健康预测。本书主要研究了基于设备诊断和预测信息的单监测信息与多监测信息的在线健康预测

模型，进而发展到设备的集成动态维护与设备的维护调度研究。因此，数据收集的方法如传感器选型、传感器布置，信号处理方法如信号降噪等都不是本书所要研究的内容。

本书是以液压泵为研究对象，来阐述整个文章的内容的。液压泵是液压系统的动力元件，其作用是将原动机的机械能转换成液体的压力能，液压系统中的油泵向整个液压系统提供动力。液压泵是靠密封容积的变化来实现吸油和压油的，故可称为容积泵。其工作过程就是吸油和压油过程。液压泵组成的系统主要有以下五部分：①能源装置，它是供给液压系统压力油，把机械能转换成液压能的装置。②执行装置，它是把液压能转换成机械能的装置。③控制调节装置，它是对系统中的压力、流量或流动方向进行控制或调节的装置。④辅助装置，上述三部分之外的其他装置，如油箱、滤油器、油管等。它们对保障系统正常工作是必不可少的。⑤工作介质传递能量的流体，即液压油等。液压泵一般包括以下部件：缸体、偏心轮、柱塞、吸油阀、排油阀、传动轴、中心弹簧、斜盘。

首先，基于液压泵的监测信息，提出了液压泵单监测信息的在线健康预测模型，在此基础上，提出了液压泵的多监测信息的在线健康预测。其次，基于在线健康预测模型，提出了液压泵整体的集成动态维护模型。液压泵这一类设备，都是由多部件所组成的，因此，在液压泵整体维护模型的基础上，进一步考虑并分析该类设备的维护调度问题。

1.3 研究目的与创新点

目前，由于工业界对预防性维护技术的需求，故障诊断领域的研究重点已逐步转向状态监测、预测性维修和故障早期诊断。预测主要采用自动化的模型探测、诊断和分析物理系统性能的退化，并计算在不可接受的性能退化发生前，设备处于可接受工作状态内的有效剩余寿命。退化分析的主要功能是指研究涉及物理属性的演变，或者导致设备失效的性能测量标准。准确并可靠的预测分析结果是成功执行基于状态的工程系统维护的关键因素，并且它对安全性能的改进、任务的规划、维修时间表的制定、降低维修成本和减少停工时间等都起着至关重要的作用。

在分析国际设备健康状态预测技术的发展并完成相关文献综述的过程中，本书分析比较了各种预测技术的优缺点。其中，隐式马尔可夫模型（Hidden Markove model，HMM）在模式识别领域有着很好的应用，近年来才被引入机械设备健康诊断领域中，并有了一定应用。但 HMM 技术的局限性使它应用于复杂系统的建模时，难以对真实情况做出高精确度的建模，导致其结果可靠度不高。隐式半马尔可夫模型是 HMM 的衍生模型，在定义完全的 HMM 结构上加入了时间组成部分，克服了因马尔可夫链的假设所造成的局限性。在解决实际问题中，HSMM 能够提供更好的建模和分析能力，提高模式分类的精度。但 HSMM 很少应用于机械设备健康诊断和预测领域，且已有的 HSMM 也没有很好地描述设备的性能退化情况。在结合目前设备维护的实际情况的基础上，本书以单设备系统为研究对象，通过对基于状态的设备维护优化相关内容的研究，可看出本研究的目的与特色在于以下方面。

（1）将考虑设备性能退化的隐式半马尔可夫模型与失效率结合，用于单监测信息的设备在线健康状态分析及寿命预测。

（2）基于单监测信息的在线健康预测模型，考虑多监测信息的设备在线健康状态分析及寿命预测。

（3）在考虑备件库存成本对维护成本与维护风险及维护效果都存在影响的情况下，基于在线健康预测分析数据优化设备动态维护策略。

（4）在设备在线健康状态有效预测的基础上，考虑多部件设备预测性维护调度优化。基于集成维护模型，对多部件设备的维护调度进行优化分析。

针对以上研究目的，本研究从预测分析的实际运用角度出发，提出一个系统地应用于 CBM 的剩余寿命预测模型。在用于诊断设备健康状态和预测有效剩余寿命的 HSMM 中，引入老化因子来描述设备性能的退化趋势。与现有的 HMM 诊断模型比较，考虑了性能退化过程的 HSMM 更贴合设备在使用中的实际情况，能更精确地描述状态转移的过程。针对多监测信息的处理问题，设计了全新的 HSMM，在最大程度上融合了多监测信息。最后，在改进后的预测分析系统的基础上，对如何将预测分析数据运用到实际的设备动态维护策略中进行了探索研究，希望能进一步提高预测分析模型用于实际生产维护计划制订的可能性。在维护策略的制定上，兼顾了维护成本和设备利用率两个指标，同时在维护成本的设计中创造性地引入了备件库存成本。在四类成本的设置上，设备更换成本设为常数值，设备维护成本与操作成本是和系统状态及系统虚龄相关的函数（虚龄的具体设置见

第5章，其取值与设备的退化状态相关)，备件库存成本与设备的维护策略相关。每次维护执行影响的设备状态参数有设备健康状态转移概率和设备虚龄两种。

围绕设备健康预测技术，开展了设备的维护优化研究，参照国内外最新的研究进展和成果，主要创新成果有以下几个。

(1)针对单监测信息的离线预测缺陷和性能衰退特征，将衰退性能引入在线预测模型，提出了在线联合多步向前健康状态识别算法，描述了设备从正常工作状态到失效状态的一系列退化过程，实现了对设备健康状态的在线描述，建立了单监测信息在线健康预测模型，实现了在线健康预测和在线剩余寿命估计。

(2)针对单监测信息的预测精度问题，利用最大似然线性回归方法对修正HSMM进行训练，提出了多监测信息在线健康预测方法(自适应HSMM)，建立了多监测信息的在线剩余寿命估计新方法，实现了多监测信息之间的有效融合，可以获得更符合实际的设备健康状态和剩余寿命。

(3)针对传统的设备维护方式，将在线健康预测模型结合到设备的维护模型中。在设备的维护模型中，考虑了设备的衰退信息(退化信息和老化信息)、诊断和预测信息、资源约束(备件和维修人员)等，建立了基于在线健康预测的双层集成动态维护模型。针对系统的维护策略问题，以每次维护活动的费用和总的维护费用率为目标，基于设备健康预测与集成动态维护模型，考虑设备维护的调整因子、多部件之间的相关性和维护调度资源的约束，建立了多部件设备的维护调度优化模型。

1.4 研究框架

本书通过消化吸收设备健康状态诊断与预测的最新理论和研究成果，在对当前已有技术的优劣分类进行分析、比较、研究后，选取HSMM对设备的健康状态退化趋势进行预测，针对维护策略进行深入研究，将与维护策略密切相关的备件库存管理纳入维护策略的优化考虑中，在一定程度上拓宽了我国设备维护管理的研究领域，对于促进我国设备维护管理的发展具有较高的理论价值和现实意义。

本书的基本思路和组织框架如图1-1所示。

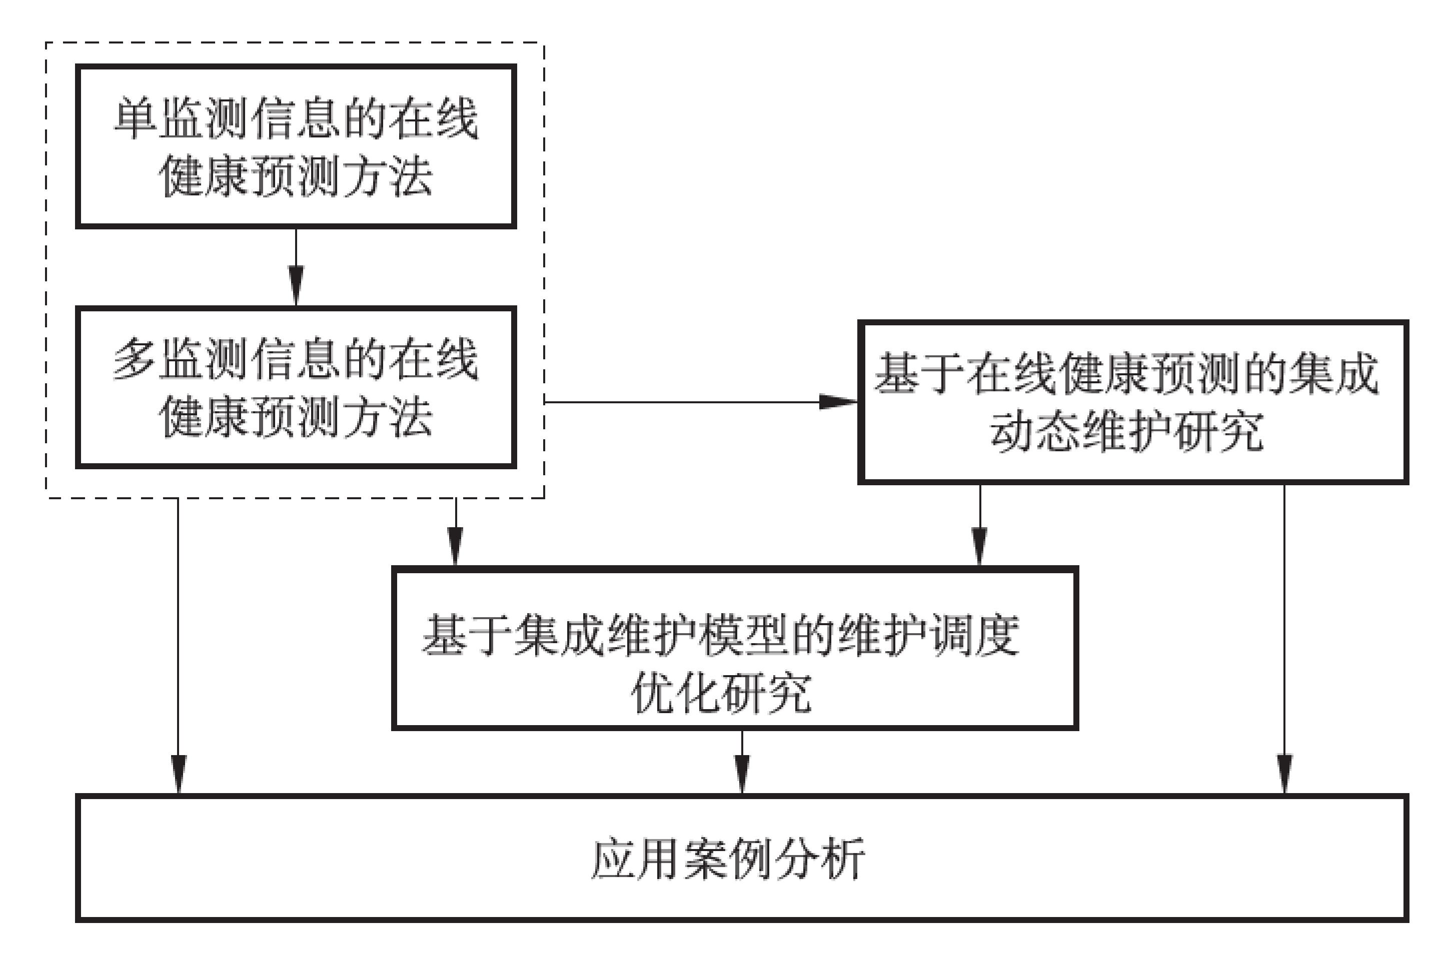


图 1-1　本书的基本思路和组织框架

1.5　本章小结

本章是全书的总体概述，概述性地介绍了相关的研究背景，在实践背景的基础上提出本研究主题，在理论背景的基础上将研究主题细化成具体的研究问题。围绕要解决的具体研究问题，本章介绍了相关的研究意义、研究目的、研究框架，以及结构安排和研究创新。本章既是全书的概述，又是全书研究的逻辑指导。



第 2 章 设备维护的概念

基于状态的维护(condition based maintenance,CBM),是指通过对设备工作状态和工作环境的实时监测,对设备当前的健康状况进行评估,并利用预诊断技术预测设备未来的可工作寿命。本章回顾了机械设备健康预测技术的已有研究成果,分析了预测模型在故障预报中的重要作用,阐述了设备维护的发展过程;最后,对这两个领域的发展趋势进行了讨论,提出了一个系统性的预测维护框架图。

2.1 引　言

工业设备和生产系统操作的可靠性对生产型企业的盈利能力与竞争能力都有重要影响,这使企业对工业生产过程和生产设备维护策略的重要性的关注日益增加。对企业生产管理而言,制定一个行之有效的维护管理系统是非常必要的。它可以帮助企业将维护成本维持在一个较低水平,同时使所有的设备都保持高效率的运作。CBM 作为一种新出现的维护决策策略,推动了设备故障的实时诊断技术和设备未来健康状态预测技术的发展。通过监测系统中关键性组件的当前“状态”,利用诊断预测技术,CBM 制定出相应的决策来执行维护[13]。系统设备的状态通过多种嵌入式传感器的定期或连续信号输出和(或)利用便携式装置定期测试

并量化获得。诊断和预测是 CMB 系统中非常重要的两部分。系统发生异常状况时,诊断涉及对故障的发现、定位和隔离。预测则需要在系统发生故障和性能退化前做出相应的预告。CBM 的目标是尽可能在有显著迹象证明设备即将发生异常行为或异常物理状态时采取相对应的维护动作,以此来避免不必要的维护行为。在通常情况下,CBM 针对不同的设备健康状态执行相应的维护行为,是一种可以有效减少不必要维护动作的设备维护方法。图 2-1 揭示了维护成本、有效剩余寿命(residualuseful life,RUL)和系统可靠性之间的关系。当距离失效点的时间接近 0 时,系统将进入失效状态,不能正常工作。当距离系统的失效时间向 0 接近时,系统的可靠性也随之降低。在 CBM 系统中,对设备和零件的剩余寿命与可靠性的预测信息将用于经济型维修计划的决策和制定中,因此,预测信息的准确性是至关重要的。

CBM 系统中的预测方法是近几年才被逐渐引入技术研究中并逐渐成为维护研究和发展中的一个热门领域的。目前已有不少的模型,都是建立在从系统中收集来的信号分析的基础上的。在未来的维修策略研究中,基于信号分析的建模方法可能会促进预测模型的发展,使其在诊断系统当前状态的同时能够预测未来的状态趋势。

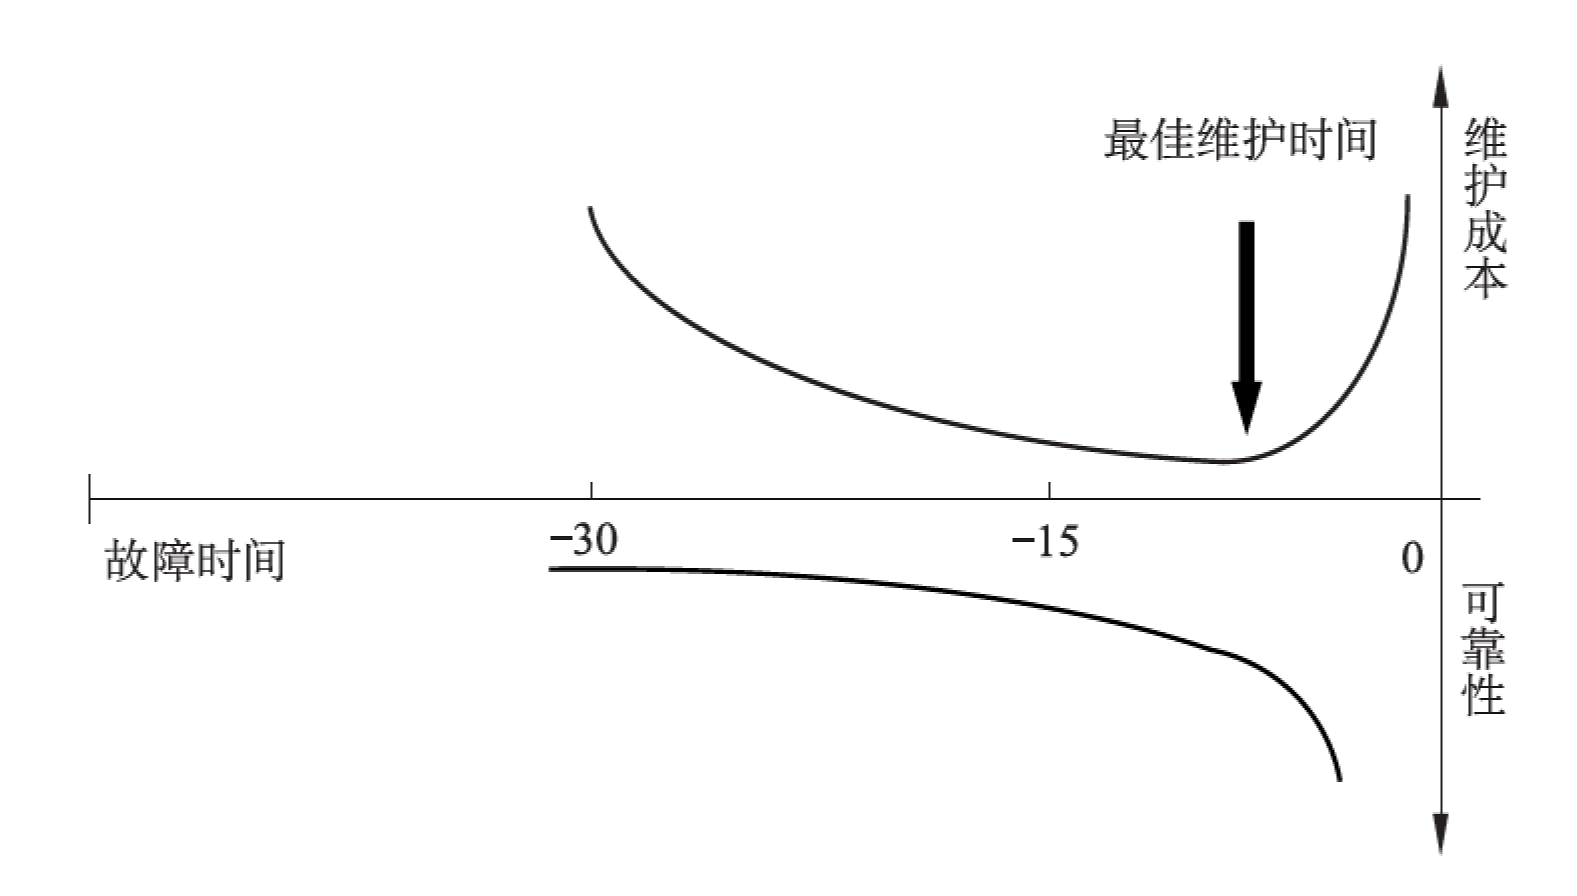


图 2-1　维护成本、RUL 和系统可靠性之间的关系

预测主要采用自动化的模型探测、诊断和分析物理系统性能的退化,并计算在不可接受的性能退化发生前,设备处于可接受工作状态内的剩余寿命时间。退化分析的主要功能是研究涉及物理属性的演变,或者导致设备失效的性能测量标准。准确并可靠的预测分析结果是成功执行基于状态的工程系统维护的关键因素,它对安全性能的改进、任务的规划、维修时间表的制定、降低维修成本和减少停工时

间等都起着至关重要的作用。虽然得到可接受准确度范围内的预测分析结果是一件非常困难的事情，但基于状态的维护所涉及的预测方法学还是在近期获得了越来越多的关注。

为了支持维护决策的制定和具有一定操作性的可靠性管理，目前已有许多的方法技术在各方面取得了不错的研究进展。这些方法按其性质特点和适用对象被分为五类，它们被视为通向决策制定管理的五步阶梯（见图 2-2）。第一步是机械设备的先验知识；第二步是数据的收集方法；第三步是数据的预处理方法，包括数据提取、转换和分析等；第四步是基于信号的故障诊断；第五步是基于数据和诊断的预测分析。

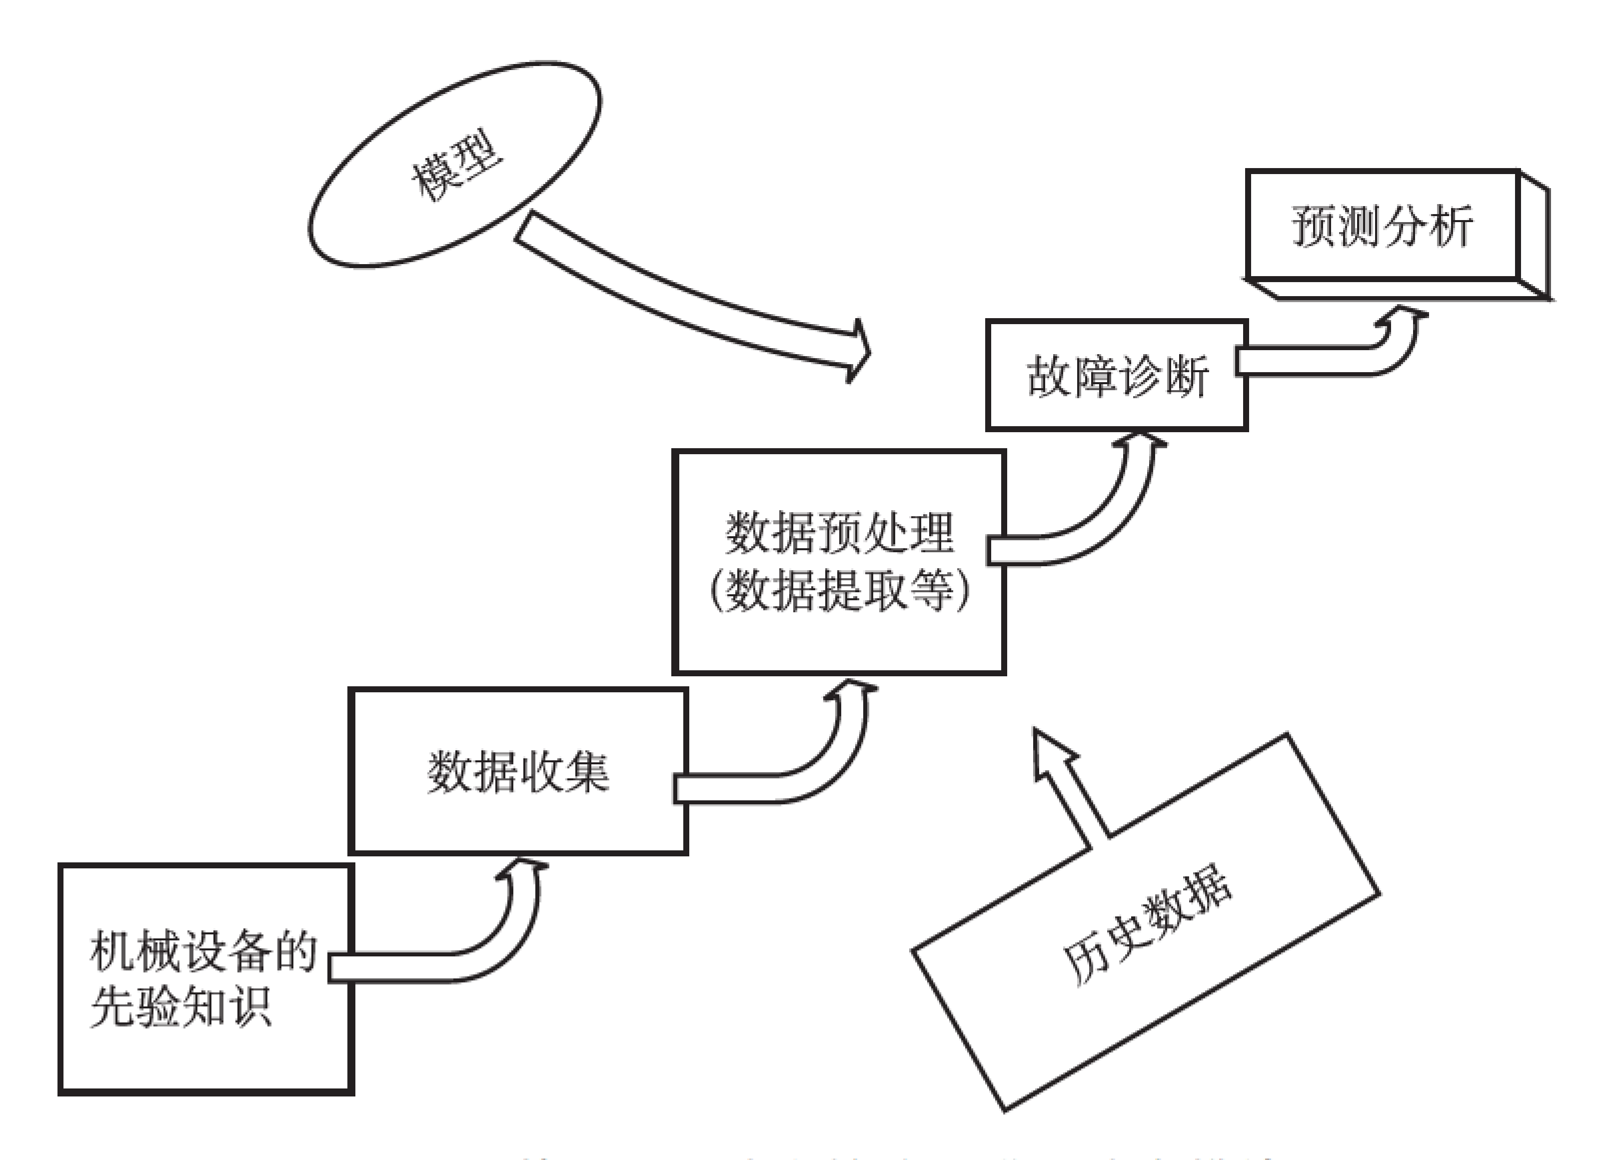


图 2-2　基于预测性维护的阶梯形技术模块

目前已有一些关于预测技术的综述文章。Katipamula 和 Brambley[14]，Jardine[15]等学者都针对预测的当前发展状态进行了简单的综述工作，但是他们的综述文章更偏重于研究诊断技术方面。Schwabacher 和 Goebel[16]对人工智能（artificial intelligence，AI）和机器学习（machine learning，ML）的概念进行了重新定义，并在此基础上对 AI 和 ML 在预测中的应用情况做了综述工作。Zhang 和 Li[17]，以及 Kothamasu1 等人[18]尝试将近年来关于应用在基于状态维护中的故障诊断技术的研究和发展工作进行了总结。在对一系列相关文献进行综述工作的基础上，这些学者对未来故障诊断和预测技术在实际应用方面的发展与挑战提出了一些见解和看法，包括需要发展快速并且准确度高的设备健康状态预测技术，建立行之有效的故

障确认方法,并研究开发相关的预测软件包。Goh 等学者[19]介绍了目前已应用于预测维护中的一些典型技术理论,并对不同的预测技术进行了 SWOT(strengths,weaknesses,opportunities and threats)分析。在前述的综述文献中,所涉及的理论方法大多限于一些传统的、典型的技术,如人工神经网络(artificial neural network,ANN)、模糊逻辑学(fuzzy logic,FL)和专家系统(expert system,ES)等。

近年来,已有关于机械设备的预测理论及其实际应用方面的大量论文发表于众多的与维修和可靠性相关的国际会议和期刊上。许多曾经成功运用于其他领域的传统方法学被逐渐引入设备健康预测的研究中,同时也有一些全新的技术及方法涌现于此研究领域内。为了提高预测模型的准确性,一些学者也尝试将两个或三个模型结合在一起来建立一个组合模型。大体来说,预测模型可分为四类:物理模型、基于知识库的模型、数据挖掘的模型和组合模型。文献综述在基于模型的分类基础上进行,对通常情况下应用于不同模型的理论技术按所属模型进行了分类,并按类别顺序对多种技术和方法进行了介绍与评估分析,对一些传统的典型方法和新引入方法的优缺点各自进行了分析比较与讨论。本章综述的组织结构如下:第 2 节介绍物理模型,基于知识驱动的方法,基于数据驱动的模型,基于模型驱动的方法,基于模型驱动的方法和混合模型,并在相应章节中对应用于上述模型的技术分类进行了综述;第 3 节对目前已有的一些维护方法进行了综述;第 4 节通过对此研究领域中日渐增长的一些研究趋势进行总结,指出目前研究中存在的一些问题,探索了未来预测维护发展中某些可能的研究方向和研究趋势。

2.2 设备健康管理的历史发展

设备维护是以企业生产经营目标为依据,以提高设备效能为目的,在调查研究的基础上,运用各种技术、经济和组织措施,对设备在使用与运行、维护与修理、改造、更新直至报废的过程中进行的管理[10]。设备维护的研究领域广泛,与现代工程技术和管理科学的理论发展密切相关。

传统的设备维修方式有定期维修(time based maintenance,TBM)、事后维修(breakdown maintenance,BM)和中途抢修(emergency maintenance,EM)等,其中

最主要的是TBM。TBM按规定的产品维修间隔期实施维修，如润滑、磨光、校准、检查等，属于预防性维修的一种。维修间隔一旦制定后，通常不再随意改变，是一个静态的设备维修策略。随着系统和设备复杂度的提高，TBM越来越暴露出其局限性。例如，不必要的维修会增加故障率，影响设备的性能或质量，造成过剩维修。并且大型复杂设备与系统的每次维修都会消耗大量的人力、物力，提高生产成本[3]。

随着设备复杂程度的增加，企业对设备维修能力的要求也逐步提高。在泰勒的科学管理思想被普遍接受的时候，设备维护管理作为企业管理的一个单独组成部分而独立出来。随着工业生产的发展，设备现代化水平的不断提高，设备维护的发展过程大致经历了四个阶段[11,12]：①事后维修阶段（1950年前）；②预防性维修阶段（1950—1970年）；③综合管理阶段（1970—1980年）；④多种维护方式并存，其中以CBM为代表（1980年后至今）。

CBM属于预防性维护的高级发展阶段。设备运行时，大多数故障从发生到发展阶段会出现一段时间的异常，并且会出现相应征兆。如果采取一定的预防措施，可能就会避免故障发生或者减缓故障后果。CBM在实施过程中，可以对设备的性能退化进行实时的监控、评估和趋势预测，并按照实际需求制订维护计划，在防止设备因故障停机的同时，最大限度地提高设备的利用率，避免冗余维护，降低设备的维护成本。CBM不仅可以提供设备性能退化监测的解决方案，而且可以让企业在制定维护策略和准备维护资源（如备件等）时拥有更充足的时间余量，特别是在备件库存管理上，使维护所需的备件库存在保证供给的情况下，可以有效减低库存水平，节约维护所需的库存成本。CBM拥有高效、节能等诸多优点，但也涉及许多专业技术的应用，实施起来难度较大。目前，CBM涉及的大量专业领域知识有信号处理、模式识别、数据挖掘等。人工神经网络、贝叶斯模型、模糊理论、专家知识系统等方法在该领域得到了广泛的应用和发展。

近年来，虽然我国工业行业的快速发展使国内生产行业的维护管理在纵向上取得了较大的进步，但与国外同行横向比较，仍存在很大的差距。目前，国内企业在维修方面普遍存在的问题和缺陷有以下方面。[13,14]

（1）企业缺乏系统的设备维护知识基础和明确的设备维护目标。设备维护只是简单地更换失效的零部件，缺乏完整的设备维护计划和对维护管理的系统研究和开发。

（2）设备维护管理系统落后，通常采取被动式而不是主动式维护。

(3) 时常存在维修不彻底或维修过剩产生高昂的维修费用,同时不适当的维修造成大量的生产损失。

(4) 缺乏预算控制,维护预算分配不当,使企业缺乏维护资源。

(5) 缺少管理层的支持,大多数的维护自动化程度低,维护系统的智能性和拓展性差,升级困难。

总体而言,我国设备的维护管理还处于初级发展阶段。以上存在的维护问题,制约了我国工业行业设备维护管理的发展,降低了制造业的经济效益和竞争能力。

2.3 设备健康预测方法的研究及进展

基于状态监测的设备寿命预测,具体而言,主要是在设备 A 运行的某一时刻 t,根据监测的(至时刻 t 的)设备 A 的运行状态和/或同类设备的历史数据,预测设备 A 由当前至失效的剩余寿命(residual life)。这里,历史数据既可以是从运行到失效过程中的状态监测数据,也可以是失效时间数据、维护时间数据等事件数据,还可以是两者的综合。Jardine 等人[15]将剩余寿命表述为

$$T-t \mid T>t,\boldsymbol{Z}(t) \tag{2-1}$$

其中,T 为失效时刻的随机变量;t 为当前时刻;向量 $\boldsymbol{Z}(t)$为至当前的状态数据。

更全面地,将式(2-1)拓展为

$$T-t \mid T>t,\boldsymbol{Z}(u)(\boldsymbol{Z}_{hj}(v),\boldsymbol{E}_{hj}) \tag{2-2}$$

其中,$\boldsymbol{Z}_{hj}(v)$为同类设备 j 在其运行时刻 v 的状态数据;向量 $\boldsymbol{E}_{hj}$ 为同类设备 j 的事件数据(尤其是失效时刻数据);$u\in[0,t]$,$v\in[0,T_{hj}]$,$j=1,2,\cdots,L$;L 为可获得历史数据的同类设备的个数;T_{hj} 为同类设备 j 的最终失效时刻。

寿命预测,既指预测变量 $T-t$ 的分布,有时也指预测变量 $T-t$ 的期望[15],即

$$E[T-t \mid T>t,\boldsymbol{Z}(u),(\boldsymbol{Z}_{hj}(v),\boldsymbol{E}_{hj})] \tag{2-3}$$

因此,设备的健康预测表主要包括以下基本内容。

(1) 状态监测技术。在设备运转过程中,尽可能精确地利用传感器的监测获得设备的运行状态信息,利用先进的数据分析技术精确评估设备的健康状态。

(2) 设备预测技术。在设备运转过程中,如果设备出现小故障或缺陷,或者

说，设备的性能状态逐渐衰退而不能最佳地完成功能时，利用设备的监测数据，预测设备的小缺陷、小故障和衰退状态，包括寿命预测和状态预测两个方面的内容。

（3）设备诊断技术。在设备运转过程中，及早发现设备的故障或者有潜在故障的零部件是很重要的，虽然一次故障还不足以影响设备的运转，使设备完全失效，但这都是潜在的早期故障，需要建立分类性能优越的模型和数据提取技术来诊断设备。

（4）信息融合技术。单传感器的数据监测不能精确反映设备的状态，需要多传感器数据之间的协同性、互补性和竞争性，以进行有效的监测、诊断和预测，高效率地将监测数据进行有效融合处理，实现更精确的健康预测。

在文献中，设备寿命预测的方法主要可以分为[15]：基于物理（第一原理）的方法、基于知识驱动的方法、基于数据驱动的方法、基于模型驱动的方法和基于信息融合的方法。

2.3.1 基于物理模型的方法

基于物理模型的方法通常采用数学模型来描述那些会直接或间接影响相关组件健康状态的物理过程。物理模型大多由特定领域的专家建立，通过对大量历史数据的分析来确立模型的参数。基于物理模型的方法用于设备的健康状态预测时，需要模型设计者掌握与系统监控相关的专业机械理论和方法。

基于物理模型的方法使用残差值作为特征值。残差值的获得来自对两组来源不同的数据不断地同时进行检测核对，这两组数据分别来自安置于某物理系统上的传感器发出的信号和对应建立的数学模型中的输出值（见图 2-3）。这类方法的前提是在正常的扰动、噪声和模型误差的影响下，残差值低于预设值，在系统故障

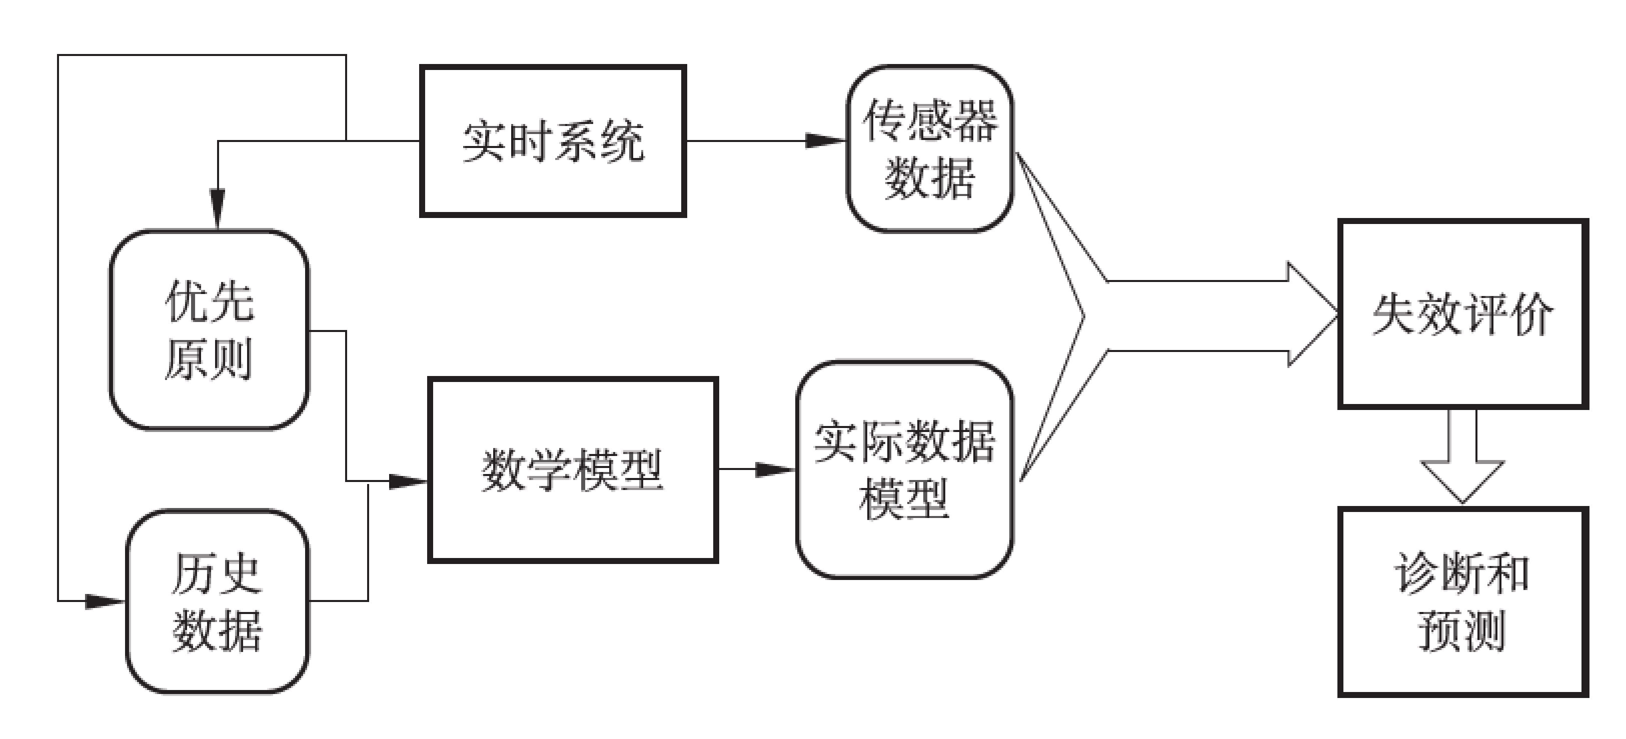


图 2-3　CBM 中基于物理模型方法的流程

出现的时候超过预设值。可用统计方法来设定确定故障出现的阈值。基于物理系统的方法适用于那些可以运用第一原则建立起精确数学模型的状况。这些模型只能被应用于对应的被监控特定系统，并且在输入命令信号时，能通过仿真做出精确的系统反应。另外，此类模型需要能够被用于组件失效的仿真，这种仿真和物理失效实验不同，它不会产生在真实硬件上进行故障播撒的费用。

物理模型在多种不同操作条件下均可以使用。在一个智能监控系统中，在各类工作负载中，包括稳定状态、转换状态和预计外的特殊状况（特殊负载，不同操作机制）等，物理模型都能良好地运作。因为对系统物理状况的理解已经被纳入监控系统的模型中，在多种状况下，特征向量的改变和模型参数紧密相关。因此，在偏移的参数变量和需要进行预测的健康特征间可以建立映射函数。进一步而言，当对系统退化的物理理解发展得更加深刻时，通过对模型进行相应的修改，此类模型可以对更加微小的故障做出预测，并且预测精确度也可随之提高。虽然物理模型具有上述诸多优点，但它的使用受到一定限制，原因在于建立模型的花费高昂，并且具有很强的组件针对性，每一个物理模型只能应用于对应的特定机械组件中[20]。而且，建立一个性能优异的物理模型是非常困难的。常见的物理模型主要包括裂缝扩展模型、损伤扩展模型、裂纹诊断与预测方法等。

Glodez[21]建立了一种用 Paris 方程来模拟裂缝扩展的模型进行齿轮寿命的预测，这个模型利用寿命预测法计算萌生的裂缝所需要的齿轮应力循环的数量，通过位移相关计算法来获得裂纹长度和强度因子间的函数关系，文献[21]通过传感器的监测信号对材料的裂纹演化建立随机模型，从而，有效估计材料的剩余寿命、材料裂纹的长度及演化速率。文献[22]根据齿轮的动力学特性方程，建立了在线估计、更新齿轮的啮合刚度及系数的模型。基于齿轮的啮合刚度及系数不断变化，裂纹扩展优化模型被用来进行齿轮剩余寿命预测。文献[23]建立了一种基于物理的转轴裂纹的诊断和预测方法。文献[24]建立了一种基于有限元法的齿轮裂纹长度的估计模型；一种齿轮动力学的仿真器；一种获取齿轮应力强度因子仿真器、一种齿轮的剩余寿命预测模型。由齿轮的刚度演化产生的动态载荷在齿轮裂纹的扩展过程中被考虑。文献[25]将齿轮的失效分为齿轮裂纹产生及齿轮裂纹演化两个阶段，Neuber 原理被用来估计在裂纹产生阶段的萌生循环数，在裂纹的扩展阶段，Paris 公式被用来获得在裂纹裂纹演化阶段转变到失效时的循环数。当建立基于状态监测的裂纹长度预测模型后，该模型可用于取代 Paris 公式来估计裂纹扩展到失效长度的概率分布。

文献[26]建立了一个轴承故障诊断模型和轴承的损伤扩展优化模型。根据传感器检测的信息，轴承诊断模型被用于估计缺陷的有效尺寸，轴承损伤扩展优化模型被用来获得缺陷的扩展率，以及未来时刻的轴承损伤尺寸，通过优化算法，对诊断模型及损伤模型的参数利用模型预测偏差进行在线更新。文献[27]把确定性的损伤扩展优化模型扩展到随机的损伤扩展优化模型。文献[28－30]对系统的失效过程进行重新分类，根据系统的损伤演化过程原理说明了系统的动态性。文献假设了系统的动态性是可以被观测的，并且是被某种常微分方程所控制的，无须了解常微分方程的优化模型。文献[31]是对文献[28－30]研究内容的更好延伸，通过结合设备的状态检测信息与健康预测的物理模型，提高设备的寿命预测精度。

文献[32]对设备监测信息的有效融合架构以及融合模型进行了有效的分析，提出了关于轴承故障诊断及健康预测的定义，且在轴承的碎裂发生后，通过碎裂扩展预测模型进行轴承寿命预测。文献[33]构建了一种碎裂扩展方程，联合有限元计算方程中需要的碎裂周围的应力，从而进行轴承寿命预测。也讨论了基于在线故障诊断结果来更新预测模型的方法。文献[34]根据振动及力学内容，轴承系统的健康预测模型被建立，有效结合了系统固有的振动频率及振动幅值、系统的失效时间及服务时间，系统的振动技术被用来获得其故障时间。文献[35]利用线性损伤方法理论来估计电路板上的焊点的损伤变化情况及数量，使用同一个方法对焊点的剩余寿命进行有效估计。通过实验说明，样本剩余寿命的均值可以利用线性损伤方法理论来获得较好的结果。在文献[36,37]中，印制电路板在振动载荷情况下的响应通过应变计进行监测，后续的焊点应变性通过解析模型进一步获得，焊点的损伤累积通过 Mine 原理进行有效估计，同时，可以获得其剩余寿命。文献[38,39]也应用设备的监测振动信号，对齿轮和设备的健康状态进行预测。

2.3.2　基于知识驱动的方法

在实际运用中，运用先验经验为一个物理系统建立精确的数学模型在通常情况下是一件非常困难的事情。物理模型的运用常常因此受到了很多的限制。鉴于此缺点，不需要物理模型的基于知识库的方法显得更有发展前途。专家系统(expert system，ES)和模糊逻辑是基于知识库的方法中比较常见的两个例子。

1. 专家系统

专家系统在化学、数学、物理、生物、医学、农业、气象、地质勘探、军事、工程技术、法律、商业、空间技术、自动控制、计算机设计和制造等诸多领域都有应用，在实

际应用中产生了巨大的经济效益[40]。建立专家系统的步骤涉及知识获取、知识表述和模型的确立三部分。其中,知识获取是比较困难,同时也是相当重要的一个阶段。所获知识的质量对整个系统的性能起着至关重要的作用。

近年来,专家系统在人工智能领域发挥了重要作用,它被广泛运用于故障诊断和预测应用中[41]。通常专家系统用于对系统的解释、监控和诊断,并对预防性及预测性修理动作和维护行为做出计划。基于规则的专家系统将领域内专家的知识进行整理并遵循一定的规则表达出来。这些规则可以是特殊的领域规则,启发式规则或来自于经验的规则,也可以通过逻辑处理器将这些规则串联为规则链使用[42]。基于规则的知识系统在对专家领域知识的提取概括上十分有效,但是将领域知识转化为规则却比较困难[43]。一旦专家系统被建立后,它不能够处理它的知识库内规则所未涵盖的新情况。而且,当知识库内的规则数量急剧增加时,可能会因为大量计算的问题导致计算机的"组合爆炸"。

早在 1989 年,Lembessis[44]就建立了一个实时专家系统用于故障诊断,该系统可以连续地监测工业设备的健康状态。随后,专家系统在设备故障诊断领域蓬勃发展,得到了广泛的应用。Butler[45]提出一个专家系统框架用于故障的探测和预测性维护(failure detection and predictive maintenance,FDPM)。FDPM 系统由无数个与专家系统相关的组件和数据库组成,其中数学模型和神经网络模型得到了很好的运用。它可以评估一个能源分配系统中组件的完好性,并对维护需求做出有效预测。Biagetti 和 Sciubba[46]设计了一个命名为 PROMISE(prognostics and intelligent monitoring expert system)的预测及智能检测专家系统。该系统可以针对存在的严重故障生成对应的实时信息,对未来时间范围内发生的可测故障或可能性故障做出预测,并对如何控制问题给出建议。

2. 模糊逻辑

模糊模型是一种重要的非线性映射模型,它能在模糊、不明确、不准确、噪声或者遗漏信息存在的情况下,提供一种简单的方法对信息做出定义,并得到解决问题的方法。它善于表达界限不清晰的定性知识与经验,借助隶属度函数概念,区分模糊集合并处理模糊关系,模拟人脑实施规则型推理,解决种种不确定问题[47]。通过语言变量的使用,模糊逻辑提供了一种模仿人脑的不确定性概念判断、推理思维方式,对于模型难以确定甚至未知的系统对象,以及非线性、滞后性严重的控制对象,实行模糊综合判断,因此它在处理复杂系统的大时滞和非线性方面显示出了独特的优越性。模糊模型的最大特点是其模糊规则库可以直接利用专家知识构造,

因而能够充分利用,并有效处理专家的语言知识和经验,而且一个适当设计的模糊逻辑系统可以在任意精度上逼近某个给定的非线性函数。它应用模糊集合和模糊规则进行推理,表达过渡性界限或定性知识经验,模拟人脑思维方式来推理解决常规方法难以对付的规则型模糊信息问题[48]。

与传统的布尔逻辑比较,模糊逻辑集合成员的取值可以为真或者为伪,它允许成员属于一个或多个模糊集,这意味着在模糊系统中,所有的规则都可以得到运用并且每条规则对输出的结果都有一定影响。但是在精确系统中,有且仅有一条规则可以被选中使用[49]。模糊逻辑使定性的和不精确的推理陈述可以用于基于规则的系统,并产生更加简单和直观且性能更优异的行为模型。和数学描述相比,模糊逻辑的语言对系统的描述更有效,并且减少了特殊性。因此,通过模糊逻辑规则下概念的引入,使管理维护动作日程的不确定性成为可能,提高了故障诊断和预测方法的鲁棒性,增加了诊断和预测结果的可靠度。近年来,随着模糊理论的深入研究,模糊模型在故障预测中得到越来越多的应用。例如,在用于故障预测的模糊模型中,利用模糊集合理论与模糊逻辑关系,在模糊知识的表达上使用故障与传感器参数之间的隶属关系,建立对应的模糊关系矩阵。

模糊模型作为一种半定量方法,在知识表述和推理方面的独特规则显示出了巨大的优势。因此,一般把模糊模型与其他模型相结合,如应用于专家系统、卡曼滤波、人工神经网络中等,使模型发挥更好的效果。Choi[50]研发了一个名为 AFDS (alarm filtering and diagnostic system)的警报过滤和故障诊断系统,该系统使用一个在线模糊专家系统,能够在系统进入异常状态时提供无缺陷的警报图片和系统层面上的失效信息,同时对系统操作者发出关于程序异常性的预测警报。另一个基于模糊模式识别规则的自适应性预测系统由 Frelicot[51]设计建立。系统中的模糊分类规则包含了隶属度拒绝权和模糊拒绝权,并通过此规则的运用对故障进行诊断。为了从隶属度拒绝模式中提取新的错误模式,一个基于模糊聚类的自学习程序被定期激活。同时,一个多步的自适性卡曼滤波被引入系统,对隶属度向量进行不断修正,提高预测结果的可靠性。文献[52]将模糊理论应用于人工神经网络,在神经网络框架下引入知识的定性表达。该组合网络结合了模糊理论与人工神经网络的优势,和一般神经网络相比,具有更强的针对性。

模糊模型适用于对复杂系统的预测,但目前模糊预测系统仍处于研究的初始发展阶段。在模糊预测系统中,由于静态知识库无法反映设备零部件的失效过程,使故障预测系统的知识表达不能包含时间参数,不能对预测对象实现实时监控,削

弱了方法的实用性，因此需要对动态知识库的建造技术进行进一步研究和运用。

2.3.3 基于数据驱动的方法

数据挖掘是从大量数据知识中发现过程的一个重要步骤，它是从大量不完全的、有噪声的、模糊的、随机的数据中提取隐含在其中的有用的信息和知识，是在一些事实或观察数据集合中寻找模式的决策支持过程[53]。它综合了人工智能、模式识别、计算智能（人工神经网络、遗传算法）、数理统计等先进技术，目前已成为计算机科学研究中的前沿活跃领域之一，在市场分析、金融投资、医疗卫生、环境保护、产品制造和科学研究等领域都获得了广泛的应用，近年来也被引入基于状态的机械设备维护领域中。把数据挖掘应用在机械设备故障诊断与预测中，是指根据机械设备的历史运行记录，对它可能的运行状态进行分类，并基于历史数据反映的运行情况，对它未来的运行趋势进行预测。

基于数据驱动的设备健康预测方法，根据设备运行状态的监测数据，通过设备预测模型，可用确定性的失效阈值或失效面定义设备失效。通过对设备的失效阈值和未来状态的分析，对设备的失效时刻进行预测，获得设备的健康状态和剩余寿命，常用的基本方法有滤波法、神经网络、贝叶斯等。

文献[54]用卡尔曼滤波器来跟踪钢带固有频率，给定了固有频率的失效阈值，从而提出一种预测钢带失效时间和剩余有效寿命的有效模型。在文献[55]中，行星上的载体剩余寿命根据粒子滤波的原理方法进行了有效预测，同时，也得到了寿命预测的有效置信区间范围。通过实验分析，结果显示了提出的方法具有针对系统的加载条件及特征变量的信噪比的鲁棒性。

文献[56]研究了两类方法有效融合预测框架：基于物理的预测方法与基于经验的预测方法。设备的关键参数通过基于物理的预测方法确定，同时，潜在的设备失效机制被获得，然后对失效机制进行有效排序，确定设备的故障模型。设备监测变量的特征通过利用基于经验的预测方法进行提取，对设备的健康演化及参数变化等进行有效预测。文献[57]将基于案例及基于模型这两种推理的方法做了比较，联合这两种方法，建立了一种进行设备故障诊断的低成本的方法。

1. 基于人工神经网络的方法

人工神经网络（ANN）是一个数据处理系统，通常是由输入层、隐藏层和输出层三层组成。每层由一定数量的、结构简单的，被称为“节点”或“神经元”的类似神经元的处理单元组成，这些单元通过使用数字化的权重彼此连接来互相作用[58]。

根据神经网络的拓扑结构和信息流的传递方式，ANN 可以分为前馈网、反馈网和混合网三种形式。

通过网络的训练程序，可以在 ANN 一系列的输出和输入之间构建结构复杂的回归函数。常见的训练方法有两种：监督学习和无监督学习。监督学习通过一系列特定的输出和输入来实现网络的训练，无监督学习的用途主要用于输入数据的分类[59]。通过网络训练机制，ANN 可用于将一系列的网络输出和输入之间的关系构建为结构复杂的回归函数。

基于 ANN 的方法具有提高处理速度、降低系统复杂性等潜在优势，因此它在预测研究领域内引起了普遍的关注。此类方法及衍生模型通过提供通用性强且可重复利用的软件及硬件组件，在建模和辅助决策方面（如数据分类）得到了广泛应用。ANN 并不依赖于先验法则或概率统计模型，并且能够非常有效地简化模型的集成过程。传统方法很难适用于解析困难的问题，如非线性、高阶、时变动态系统等，但是 ANN 可以很容易地解决这类问题的建模问题，甚至对不能解析的问题，也可以建立对应的 ANN 模型。通过对模型的调整，可以增加错误的容许量，并且在系统的成熟中自我调整，对结果做出补偿。

ANN 及其衍生模型又称黑盒子。一方面，黑盒子保证了模型容易建立；另一方面，在预测结果中缺乏原理性的直接分析。虽然与物理模型和基于知识库的方法相比，建立 ANN 模型相对容易，但对系统设计者来说，在实际运用中，将领域知识用到人工神经网络是非常困难的。对设计者来说，预测过程本身是一个“黑盒子”，很难将 ANN 的输出和物理现象联系起来。当 ANN 的规模增长时，训练会变得非常复杂。举例来说，如何设置每一层需要的处理节点数量就是一个非常令人困扰的问题[60]。

ANN 在预测的应用上分为两类：一类用作非线性函数的拟合，并在此基础上通过数值估计和数据分类的应用来预测系统的失效特征和趋势；另一类和系统的反馈连接一道用作系统退化的动态过程建模，并计算系统有效剩余寿命的预测值[61]。ANN 可作“预测器”，把时间序列的历史数据映射到未来数据，也可把 ANN 作为“组合器”[62]，给出常规预报方法的最佳组合。由于 ANN 具备将不同渠道，甚至分离的渠道中的数字信息融入模型的能力，因此一个设计整合良好的 ANN 模型可以快速精确地执行在线模式识别任务。从这些系统中所提取的数据可以共同用作设备故障诊断和健康状态预测。与传统的非线性组合预报相比，神经网络组合预报模型在提高预报精度的同时无须对模型结构作限制，优势

突出[63]。

文献[64]利用 ANN 模型来研究轴承故障分类。Wang 等人[65]运用 ANN 模型来解决旋转机械故障诊断的问题。文献[66]探讨了 ANN 模型在电子机械中的故障诊断问题的应用。文献[67]用 ANN 模型进行区分故障类型对于提取的特征数据、环境和振动变量的影响。文献[68]提出在有些情况中没有办法以特征变量的空间来定义失效,但却能依据专家知识和操作经验定义失效。因此,在这种情况下,用前馈型神经网络对特征变量进行预测,用 Sugeno 模糊推理模型对失效进行定义,从而进行设备性能可靠度的预测。文献[69]建立了两类基于 NN 的寿命有效预测方法,通过案例分析可知这两种方法可以获得较高的预测精度。在方法框架中,基于设备的历史监测数据,多个前馈型反向传播的神经网络被建立,从而轴承服役时间被有效估计,用一个振动幅值阈值来描述轴承失效。Tran 和 Yang[70]应用自适应神经网络预测设备的健康状态。Sou-Sen Leu 等人[71]提出了神经网络和隐马尔可夫模型的集成模型预测设备的寿命。文献[72-76]也是应用 ANN 对设备的健康进行预测和对设备的有效剩余进行预测的。

在 ANN 中,要求人工神经元对系统的输入信号进行变换,该变换要求当神经元所获得的输入信号超过累积效果阈值时,就可激发该神经元,否则就抑制该神经元,即人工神经元需要一个变换函数,用来执行对神经元所获得的网络输入进行变换,该变换函数称为激活函数。常用的激活函数有线性函数、非线性斜面函数、阈值函数和 sigmoid 形函数[77]。小波动态神经网络是神经网络的衍生模型之一,是小波分析理论与人工神经网络理论完美结合的产物。它兼容了小波分析与人工神经网络的优越性,在判别和分类问题上有其独到之处。它既能够充分利用小波变换的时频局部化特性,又可以充分发挥人工神经网络的自学习、自适应能力,从而具有较强的逼近与容错能力,非常适用于物理信号和图像的分析。

一些学者提出了动态小波神经网络 DWNN 系统来处理预测中的分类问题。在在线执行和应用前,需要对模型进行训练和验证。DWNN 可以使用时间相关的训练方法,如以 Levenberg-Marquardt 算法为代表的梯度下降技术,也可以使用一些进化算法,如遗传算法[78]等。DWNN 能够用动态模式来处理,提取自暂态序列并保持动态的特征,这些提取到的特征可以和描述指定时间片段下过程的时间相关向量融合。一个训练良好,结合了有效剩余寿命计算机制的 DWNN,可以扮演在线预测操作者的角色。它的缺点是需要一个足够大的数据库来完成特征提取、训练、验证和优化工作。

文献[79]描述了基于动态小波神经网络的寿命预测方法。在它的案例分析中，验证了该方法的可行性，轴承的振动信号功率谱密度被用作模型的输入特征变量，需要假设基于功率谱密度的失效阈值在剩余的预测过程中。Wang 和 Vachtsevanos[80]建立了一个 DWNN 预测框架。在网络中将临时信息和存储能力纳入功能性中，可以执行故障的预测任务。模型的预测结构基于一个静态“虚拟传感器”，该传感器在已知故障数据的阈值范围和一个可根据故障组件的当前状态推测未来时间状态的预报器间建立连接，并据此揭示故障模式随时间推进的演化过程，预测组件的有效剩余寿命。阈值范围与预报器的构造均基于 DWNN 模型，起着映射工具的作用。Gebraeel 和 Lawley[81]在退化模型的基础上使用 DWNN，利用传感器的状态参数来计算部分退化组件的有效剩余寿命分布，并可实现持续更新。通过使用实时的传感器数据对神经网络进行“监督”训练可以获得初始的预测失效时间。这些初始值被用来构造一个被监控组件的先验失效时间分布，并使用贝叶斯理论对先验分布进行不断更新。这个模型的独特之处在于，具有根据传感器的状态信号来对组件有效剩余寿命分布进行更新的能力。这些实时的传感器信号可以捕捉到组件的最新退化状态，并据此更新与组件的物理退化直接相关的寿命分布。

多项式在描述物理过程和动态系统时表现出来的近似普遍性先后被 Kolmogorov 于 19 世纪 40 年代，Gabor 于 19 世纪 50 年代证实。大致而言，许多设计中的主要元素可以通过归纳法进行建模。虽然利用数学原理和法则是最常用的方法，但其他的一些逻辑因素和先验知识模块也表现不俗。多项式神经网络 PNN 利用了 KG(Kolmogorov，Gabor)多项式和数学几何[82]。与只使用了 KG 函数中前两项的多层神经元网络相比，PNN 利用了高阶序列和交叉耦合的非线性特点。文献[83]使用 PNN 来分析直升机传动装置中的正常和故障振动信号，该模型可以用作一般性故障的诊断、隔离和评价估计。文献中的数据来自 9 次故障播种索具实验，每个实验各自对应 6 个不同故障/非故障状态中的一个。这些数据被用作模型的训练和 PNN 分类任务完成情况的评价。特征值提取自时间序列的振动信号的光谱幅值，通过使用 MLPP(multiple-look post-processing)策略使振动信号的分类达到最优。

自组织神经网络 SOM 通常用于处理特征空间的建立和系统退化诊断问题。网络模型中的神经元列阵全部互相连接，即每个神经都接收相同的外部输入，并在外部输入出现时，同时开始工作。网络采用“胜者优先”的学习机制，即选出的一个神经元网络训练好后，当同样的模式出现时，某个神经元将兴奋起来，表示该神经

元认识这个模式,这种信息处理模式源于人脑内的感觉映射。在对输入数据进行标准化处理后,自组织神经网络可以进行迭代训练[84]。在训练的每一步,每个样本矢量 X 均从输入数据组中随机选取而得,矢量 X 和网络中权重矢量的距离初始值随机生成,并使用某种距离测量方法计算,如欧几里得距离。最靠近 X 的权重矢量所属单位即是映射单位,又被称为最匹配单位 BMU(best matching unit)。当确认 BMU 后,BMU 的权重矢量和它的拓扑邻居被随之更新,使其更接近输入矢量 X。在训练程序结束时,权重矢量根据它们在输入空间中的距离而分类聚拢。

SOM 具有很好的样本聚类和模式识别能力,加之无监督的自学习方式,使其在机械故障模式识别和故障预测中获得广泛应用。和一些传统方法,如 PCA 相比,SOM 可以用来处理具有高偏离度的非线性数据。SOM 的无监督学习特性不需要事先获得和输入向量对应的目标值,因此,在输入数据所属类别的信息未知的情况下,它仍可以用于数据分类工作。SOM 是揭示状态空间结构的有力工具,同时,它能有效地将系统行为可视化,是系统监测和系统退化诊断的有力工具[85]。文献[86]通过使用 6 个振动信号数据来对 SOM 进行训练,训练后输出的 MQE (minimum quantization error)指标来评价轴承滚珠的退化情况,并预测有效剩余寿命。针对滚珠从初始完好状态到完全失效的最终状态的全过程,SOM 都建立了适当的退化指标。

综上所述,ANN 用于预测领域存在如下优点。

(1)作为“黑盒子”系统,不需要建立基于系统物理规律的数学模型,建模容易。

(2)更好的容噪性,能很好地处理常伴随大量噪声的传感器信号[87]。

(3)优秀的非线性映射能力,能以给定的任意精度逼近任意的连续函数。

总之,以上特点使 ANN 能够较好地反映机械设备实际工作状态的发展趋势与状态信号的关系。同时,ANN 能进行多参数、多步预报,在故障预测方面具有很好的应用前景。

2. 贝叶斯网络方法/模型

工程中需要进行大量科学、合理的推理,而且工程实际问题大多比较复杂,其中存在的大量不确定性因素给准确推理带来了困难。不确定性推理也是人工智能的重要研究领域,尽管许多非概率模型在人工智能的领域都得到了广泛应用,但是研究人员认为在常识推理的基础上构建和使用概率方法也是可能的。为了提高推理的准确性,Judea Pearl 于 1988 年提出了贝叶斯网络[88](BN,Bayesian network),用于处理人工智能中的不确定性信息。BN 又称信度网络,是贝叶斯方法

的扩展，自提出后便成了研究的热点，是目前不确定知识表达和推理领域最有效的理论模型之一。

BN 来自概率论和图论的综合应用。它是基于概率推理的图形化网络，而贝叶斯公式则是这个概率网络的基础。BN 是一个具有概率分布的有向弧段（directed acyclic graph，DAG），它由节点和有向弧段组成。节点代表随机变量，连接节点的有向弧段代表了节点间的互相关系（由父节点指向其后代节点）或概率关系，没有父节点的节点用先验概率表述信息。节点变量可以是任何问题的抽象，如测试值、观测现象、意见征询等。适用于表达和分析不确定性与概率性的事件，应用于有条件地依赖多种控制因素的决策，可以从不完全、不精确或不确定的知识或信息中做出推理。可以用 $B(G,Pr)$ 来描述 BN，这里 G 是不构成回路的有向弧段，Pr 是条件概率，可通过递归乘积对其进行分解[89]。BN 是为了解决不定性和不完整性问题而提出的，经过多年的发展已逐步成为处理不确定性信息技术的主流，在计算机智能科学、工业控制、医疗诊断等领域的许多智能化系统中都得到了重要应用。在设备维护领域，BN 对于解决复杂设备不确定性和关联性引起的故障有很大优势，成为众多学者的研究对象。

BN 的建造需要知识工程师和领域专家的共同参与，在实际操作时可能需要反复交叉进行使用与不断完善，这是一个复杂的任务。面向设备故障诊断和预测应用的 BN 的建造所需的信息来自多种渠道，如设备手册、生产过程、测试过程、维修资料及专家经验等。首先将设备故障分为各个相互独立且完全包含的类别（各种故障类别至少应该具备可以区分的界限），然后对各个故障类别分别建造 BN 模型。需要注意的是，诊断模型只在发生故障时启动，因此无须对设备正常状态建模。通常设备故障由一个及以上的因素造成，这些因素又可能由一个或几个更低层次的因素造成。建立起网络的节点关系后，还需要进行概率估计。具体方法是假设在某故障因素出现的情况下，估计该故障因素的各个节点的条件概率，这种局部化概率估计的方法可以大大提高效率[90]。

动态贝叶斯网络（Dynamic Bayesian network，DBN）是一个包含了统计过程的有向图模型，可以对系统在时间进程上进行监控和更新，并进一步预测系统未来的状态。DBN 的目的是在随机变量的半无限样本集中建立一个概率分布模型，其中随机变量的进程与一些事件模型相对应。在一个 BN 中，通常需要定义如下组成部分：先验网络 $P(X_0)$、转换网络 $P(X_t|X_{t-1})$ 和观测网络 $P(Y_t|X_t)$。先验网络表述了在起始时间片段 $t=0$ 时，BN 中所有变量的先验概率分布。转

换网络阐明了每个变量在每个时间片段 $t=1,2,\cdots,n$ 上变化的概率。观测网络说明了在时间片段 t 上，观测节点和其他节点间的关系。DBN 中的每个变量均和时间片段相关，记为 X_t。模型中有两个关键参数：一个是建模过程中涉及的时间跨度 T，即一共有 T 个时间片段；另一个是与时间片段相关的变量 X_t，其个数为 n，称为样本空间 n[91]。

Sheppard 和 Kaufman[92] 在 BN 的基础上建立了一个设备健康诊断模型，该模型中包含了失效概率、设备的不确定性和故障迹象的预测等信息。他们也使用了 DBN，通过对整个时间段的设备状况建模，来执行预测的工作。Przytula 和 Choi[93] 使用了贝叶斯信度网络(BBN，Bayesian belief net)作为预测框架，对系统的预测和有效剩余寿命的估值都可以在此框架下完成。在 Gebraeel 和 Lawley 等学者[94] 设计的预测模型中，使用 BN 对先验概率分布进行更新，并完成对后续失效时间点的预测工作。Dong 和 Yang[95] 设计了一个基于 DBN 的预测模型，可以用作钻头零件有效剩余寿命的预测。在如何建立 DBN 并设计相应的算法方面，他们提供了详细的说明步骤，采用基于部分过滤算法的预测过程估计一台垂直钻孔机中零件的有效剩余寿命。文献[96,97] 以贝叶斯方法进行在线更新衰退模型的参数，通过联合轴承的失效阈值，获得寿命分布的封闭形式。在文献[98] 中，讨论了设备的运行环境存在时变情形的寿命预测。文献[99] 讨论了同类设备的历史数据中的失效时间的数据可得情形的寿命预测。文献[100] 对设备的衰退模型随机参数没有呈现正态分布的情形进行了讨论；设备性能衰退模型随机参数在符合更普遍的分布形式时，对寿命预测方法进行了有效的描述。文献[101] 用多项式的模型进行外推特征变量来对直升机齿轮箱的剩余有效寿命进行预测。

BN 用条件概率表达各个信息要素之间的相关关系，能在有限的、不完整的、不确定的信息条件下进行学习和推理，能很好地应对不确定性问题。在多信息源存在时，它能有效地对多元信息进行表达与融合。例如，BN 可将故障诊断预测与维修决策相关的各种信息纳入网络结构中，按节点的方式统一进行处理，能有效地按信息的相关关系进行融合。但是贝叶斯网络建模时需要大量的故障数据，包括设备受到重大损伤时的数据，这些数据很难获得，或虽能获得但成本高昂。

2.3.4 基于模型驱动的方法

基于模型驱动的设备健康预测方法，这类方法通常认为状态监测是影响设备健康的主要因素。常用数学模型来描述设备的衰退行为，进而通过数学模型预测

设备健康状态和剩余寿命。常用的方法包括隐式马尔可夫模型、隐式半马尔可夫模型、失效模型、GM 模型等。

1. 隐式马尔可夫模型和隐式半马尔可夫模型

隐式马尔可夫模型 HMM 是随机过程模型的一种,它能够描述双重内嵌于系统底层且不可见的随机过程,模型名称中的"隐"即来自它描述不可见过程的能力。作为一个参数模型,HMM 通过对大量的实验数据进行统计分析,得到参数的估值。

HMM 最开始广泛使用于模式识别的研究中,近年来也被引入了预测分析的建模中,具有其他一些传统方法所不具备的特质。HMM 不但能反映出设备状态的随机性,同时能够揭示出这些设备的隐藏状态和状态间的转换过程。进一步而言,HMM 的理论基础强健,构建合理,并且算法易于软件的实现,但是 HMM 模型存在较多约束。比较重要的一点是,连续系统的行为观测必须是相互独立的。马尔可夫链本身的一条重要假设是在时间节点 t 上,给定状态的转移概率只取决于系统在时间节点 $t-1$ 时所处的状态。而且,模型中的状态持续时间遵循指数分布。换言之,HMM 不能详细准确地描述模型中的时间结构。在实际应用中,这些限制不一定能得到满足,并因此影响模型的精确度。

文献[102]构建了一种设备故障诊断和寿命预测的综合架构——基于隐马尔可夫模型的框架。得出预测主要服务于设备健康状态发生变化的趋势估计,但是,文中对于设备出现故障前的寿命预测没有很好地进行讨论。文献[103]发展了轴承失效的诊断和预测的联合方法,主要包括主成分分析法(prcinciple component analysis,PCA)、HMM 及一种自适应的随机寿命预测模型。PCA 用于提取监测数据的主要特征,HMM 用来诊断当前轴承的状态,自适应的随机寿命预测模型用来预测并且更新设备健康指标发展趋势,从而进行剩余寿命的预测。文献[104,105]也用 HMM 对设备进行故障诊断和寿命预测,为设备运转过程中出现的每个健康状态,分别建立 HMM,并根据传感器的检测数据,对健康状态的转折点进行估计,从而估计其状态转换点的条件分布,但没有详细讨论怎样预测设备剩余寿命。文献[106,107]将分级的 HMM 看为动态贝叶斯网络执行诊断与预测,能直接来估计设备各个健康状态间的状态转移概率,采用蒙特卡洛仿真方法来估计设备剩余寿命和置信区间,钻头案例验证了此方法的有效性。文献[108]同样应用了 HMM 对设备执行在线诊断与预测。

隐式半马尔可夫模型 HSMM 在一个设计完善的 HMM 基础上添加了时间组

件。为了解决 HMM 不能清楚描述状态持续时间的问题，一些学者[109,110]提出了 HSMM，可以对状态持续时间的概率问题进行清晰描述。一个常见的设计是挑选与实际运用中真实寿命概率方程接近的概率函数来代替状态持续时间的概率密度函数。从本质上而言，HSMM 是在 HMM 的基础上添加了一个描述清晰的状态持续时间概率函数，但是添加函数后的模型不再遵循严格的马尔可夫过程。HSMM 和 HMM 类似，不同的是，每个状态不只对应一个观测值，而是可以对应一系列的观测值，这些对应于停留在状态 i 时的所有观测值在建模中被看作一个整体。隐式半马尔可夫链在确定复杂概率分布问题和时间结构表达问题上均具有很强的柔性。文献[111]针对 UH-60A 型黑鹰直升机中的主要行星传动系统建立了一个故障分类模型。

文献[112,113]论述了传统 HMM 的局限性，表明了 HMM 主要用指数分布来表示每个健康状态的持续时间，与设备的实际演化情况相违背，所以，每个健康状态的持续时间需要被明确地描述，在此基础上，提出了 HSMM。通过案例说明了 HSMM 具有更好的有效性和状态的识别性。文献[114]进一步研究了状态持续长度和设备的老化相关的情形，并且，老化因子被引入 HSMM 中，借此来描述设备在不同的时间点，每个健康状态的持续时间分布。在案例分析中，设备在将近发生故障时，构建的方法可以更精确地预测水泵剩余寿命。

文献[115]表明许多设备的失效过程包括稳态过程与非稳态过程，在设备正常运行的阶段，主要是稳态过程。从设备出现故障到设备最终失效的阶段，主要对应的是非稳态过程。对稳态过程来说，主要通过可靠性数据来执行寿命预测。当设备过渡到非稳态过程时，对于设备的传感器检测数据，假设呈现指数增长，利用设备的检测数据来进行设备的寿命预测。在文献[116]中，采取了 Logistic 回归方法，建立设备特征变量和失效概率间的联系，采取时间序列模型用来进行特征变量预测；利用 Logistic 模型，前期的预测值作为模型输入，设备的剩余寿命的有效预测被执行。Wu 等人提出了联合小波变换的 HSMM 进行设备的故障预测[273]。基于 HSMM 的寿命预测模型很好地描述了设备当前状态(劣化程度)与监测信息之间的概率函数关系，并且它仅用当前信息估计下一个时间点状态。但是，由于计算复杂度问题及多源信息融合问题，HSMM 无法有效地进行在线健康预测。

另外，多伦多大学 MAKIS 教授团队也做了一些这方面的工作，Tang 和 MAKIS 等人基于 HMM 模型，考虑了带有部分故障观测数据系统的参数估

计[274,275]，但是他们仅假设逗留时间服从指数分布，没有有效地考虑状态的逗留时间。

2. 失效率和比例强度模型

失效率是指工作到某一时刻尚未失效的设备，在该时刻后，单位时间内发生失效的概率，一般记为 λ，它也是时间 t 的函数，故也记为 $\lambda(t)$，称为失效率函数，有时也称为故障率函数或风险函数[117]。失效率作为设备寿命分析中的一个重要指标，它的数学特质能揭示出数据中多种不同的特征，被广泛应用于设备有效剩余寿命的预测中[118]。

文献[119]设计了名为 GAMMA 的随机过程，通过用失效率求得均值来预测轴承上旋转组件的有效剩余寿命。通过对振动信号的分析，专家用状态信息作为判断的依据。文献[120]对失效率服从 Birnbaum-Saunders 分布的系统进行了寿命分析。

但是，系统或零部件的失效率不仅受操作时间长短的影响，还受操作环境下的各种环境参数和操作参数的影响，如气温、湿度、工作负载等。比较常见的一个问题是，在可靠性数据的分析中，并不是所有的数据都在同样的工作状况下收集获得。针对那些有效剩余寿命受参数影响严重的系统，部分失效率模型被引入了预测分析中[121]。这类模型一开始被广泛应用于生物医学领域，近来，研究可靠性维护管理的学者才日渐对它产生了浓厚的兴趣。在可靠性数据的分析中，一个经常出现的问题是并非所有的数据都在同样的工作状况下收集获得，部分失效率模型将情景概念引入失效率方程中。情景对失效率的影响可以使观测到的失效率比基准失效率更高（例如，当设备在恶劣状况下运行时），也有可能使失效率观测值低于基准值（例如，当设备的运行状况得到改善时）。部分失效率允许更多类型的数据挖掘风险模型来描述情景对设备健康状态的影响。

文献[121]使用部分失效率概念建立了一个可以对复杂多组件系统进行可靠性评估和风险预测的模型框架。该模型修改了部分失效率公式，使其可以适用于时间变化的随机情境，将任意时间下非静态随机环境中的离散数据组进行转换，并在非线性网络环境下执行。失效率的基准值来自一个参数化的可靠性模型，此模型使用经验值来评估可靠性。文献[122]为独立的旋转机械组件建立了一个部分失效率模型，该模型考虑了多个退化特征，在获得实时退化信息的基础上，预测组件有效剩余寿命的均值。文献[123]中设计了一个提取常见失效信号的算法，设定失效特征编码为取决于时间的情景变量，并使它们互相作用。文献中的 Cox 失效率模型

可以有效处理事件序列的情景，序列中的大量事件类型都基于前述的常见失效特征。此模型可以对设备故障的发生做出预警，为设备真实失效事件的发生预留出充分的准备时间，帮助预防性维护计划的制订。

文献[124,125]采取比例强度模型进行设备寿命的预测，并以此来评价 PM 的效果。在文献[126]中，比例风险模型(proportional hazards model，PHM)被用来对设备可靠性及剩余寿命进行预测，且用 Markov 过程来描述设备内部和外部的协变量发展过程，因此，在某一个时刻预测协变量的未来发展趋势，可结合比例风险模型来预测设备剩余寿命。文献[127]划分了水泵的维护方式等级，并且假设水泵的轴承的寿命分布与造纸机的轴承具有一样的形状函数与不同的尺度函数，在此基础上，计算水泵轴承的风险函数值，预测寿命。

3. 灰色模型 GM(1,1)

部分信息已知、部分信息未知的系统称为灰色系统。由于相关信息不充分、欠完整、不确定的系统大量存在，使得灰色系统在各个领域得到了广泛应用——曾被成功地运用于管理、经济、金融和工程中[128]。即使在数据不完全时，灰色模型也能有效地对系统分析、建模，并做出预测。在灰色系统中，信息和原理既不像在白色系统中那样完全清晰，也不像在黑色系统中那样完全未知。灰色系统将每个随机变量设置为灰色量，使之在一定范围内变化。它可以直接处理原始数据并对数据的本质规律进行研究。灰色预测模型可以应用于数据量较少的情况中，同时可以在 Matlab 系统下轻松实现。目前，关于 GM(1,1)的研究主要集中在两个方面：①加强对原始序列的处理，例如进行变换处理以增加原始离散数据的光滑度；②改进 GM(1,1)模型，使其具有更好的拟合优度和预测精度[128]。

影响机械设备工作状况的因素很多，其中既有确定性因素，又有非确定性因素，即“灰色”因素。因此，灰色模型适用于机械故障预测。Huang[129]将灰色预测模型应用到了制造过程的监控管理中。当平均偏离发生时，灰色预测器能够监督样本均值，尤其是在子集成员数量较少时。可见，灰色预测器对子集的成员数量非常敏感。也有学者将灰色模型和模糊模型组合[130]，探索了灰色模型在设备预测领域使用的可能性，拓展了灰色模型 GM(1,1)的适用范围。文献[131]将具有差分形式的灰色模型 GM(1,1)扩展为 GM(1,1,w)预测模型，用模糊贴近度来优化参数 w，再进行故障预测，工程实例证实了此方法的拟合优度和预测精度均高于未优化的 GM(1,1)，在样本空间较小的情况下能得到更好的预测结果。Gu 等学者[132]尝试使用灰色预测模型来预测电子仪器的失效时间，但其工作还处于探索阶段。

2.3.5 基于信息融合的方法

目前,随着计算机技术的迅速发展,多传感器的技术也得到了越来越多的关注。多传感器的融合技术利用了计算机的智能与快速的运算能力,消除了数据信息间的差异,有利于数据处理质量的提高。多传感器信息融合技术是计算机科学、数学、智能算法及管理领域等多学科的综合交叉应用。随着设备复杂性的提高,对设备的性能要求也在逐步增加,因此,对传感器的数量和种类要求也在增加。它表示了在面对同一检测对象时,各种传感器的监测信息及监测信息的处理方法被综合应用,从而获得设备的全面监测信息。同时,设备监测信息的精度和可靠性得到了极大的提高。来自多传感器的监测信息,具有多样性、复杂性,信息容量大的特性。信息的处理,不同于单个传感器信息的处理,因而,这类技术的研究变得非常重要。

在设备故障诊断和寿命预测中,考虑多传感器的融合技术主要有以下三个原因。

(1) 在故障诊断和寿命预测复杂化的情况下,对传感器种类和数量的要求也在增加,对于设备的不同部位,可以利用不同的传感器获得不同类型的信息。相较于单个传感器的只能获得单一信息的情形,多传感器可以获得多样的状态监测信息。在单一信息的情形下,进行设备故障诊断和寿命预测的精确度不是很好,而利用多样化、不同类型的监测信息,可获得可靠的设备诊断和寿命预测结果。

(2) 设备故障的发生与诊断是一个非常复杂的过程,相同情形的信息可以反映不同的故障类型。比如,机械转子的振动异常故障可以由轴承座发生松动、轴承发生不对中、不平衡等原因引起。所以,在对机械转子进行振动检测时,就包含了大量的关于机械转子的状态特征信息,充分应用转子的这类特征信息,可以获得更准确的转子故障类型。

(3) 在设备的故障诊断和寿命预测过程中,因为传感器的监测信息误差、设备运转过程中的噪声及设备使用过程中的不确定性等,对传感器的监测数据质量造成很大的影响,会产生不完整、不准确及模糊的监测数据,具有监测的不确定性。

基于信息融合的设备健康预测,主要有三类方法:第一类方法就是将获得的多监测数据直接作为状态空间模型的输入,没有经过任何的处理[133−135],文献[133]建立了一个状态空间模型,将检测数据作为多维时间序列用于模型的输入,预测设备的健康状态,以及每个健康状态的均值和方差。文献[134]应用传感

器的信号描述状态空间模型中隐藏的设备健康，预测设备的剩余寿命。第二类方法将对多传感器进行数据层次的融合[136-139]，文献[136]利用 PCA 变换多传感器的信号，形成具有较低维数的数据集合，应用随机滤波方法预测航空发动机的设备健康和剩余寿命。文献[137]应用 PCA 对数据进行处理，在获得较低维数的数据集合后，通过神经网络和小波变换对设备进行寿命预测与健康预测。第三类方法将对多传感器进行预测层次的融合[112,140]，文献[112]首先建立了基于每个传感器检测信息的 HSMM 诊断和预测模型，其次通过用 F-test 调整每个传感器的融合权重，建立多传感器的 HSMM 诊断和预测模型，对设备进行健康诊断和寿命预测。文献[140]应用随机滤波方法和利用每个传感器的检测信号，分别对设备进行剩余寿命预测和健康状态诊断，最后，对每个预测结果利用线性权重策略进行有效融合。Wei 等人[141]考虑了对一类潜在退化的多传感器动态系统剩余寿命进行预测。基于多个传感器的监测数据，采用分布式融合滤波递归识别隐藏的衰退过程。然后，基于拟合的衰退状态和更新操作过程中的参数，预测设备的剩余使用寿命。不确定性指标用来定量地评价增加的多传感器信息预测设备剩余使用寿命的有效性，并对主要结果进行了验证和实际案例研究。El-Koujoka 等人[142]研究了一个非线性过程的多传感器故障检测和隔离（MSFDI）算法的设计与开发问题。所提出的方法基于一个不断演进的 multi-Takagi Sugeno 模型框架，每个传感器的输出都可用一个来自可用输入/输出的测量数据模型进行估计，提出的 MSFDI 算法被应用于连续流搅拌反应釜。仿真结果表明 MSFDI 算法的有效性。预测的主要技术如表 2-1 所示。

2.3.6 混合模型

设备在故障发展过程中包含了多种趋势，其中既有确定性趋势，也有随机性趋势，设备处于早期的轻微故障时这种现象表现得尤为明显。因此，在实际应用的预测过程中，各种特征参数的趋势是多样化的，单一预测方法的使用很难得到准确的预测结果。为提高预测的准确度，应综合应用多种预测模型。一个设计得当的基于状态的组合预测模型可以将两种甚至更多预测方法融入模型，此类组合模型在数据提取、数据分析和建模上有如下的优势：①单一预测理论的缺点可以得到相互弥补而削弱或抵消，而各自的优点却可以得到充分的利用；②计算复杂度可以得到有效降低，减少程序的运行时间；③可以提高预测结果的准确度。

针对传统的非线性组合预测模型存在的不足，ANN 被作为“组合器”引入组合

预测模型。许多研究将神经网络和其他的一些数据处理方法，如专家系统、模糊逻辑、灰色系统 GM(1,1)等，结合起来建模。Brotherton[60]将规则提取技术应用到 DL-EBF(dynamically linked ellipsoidal basis function)神经网络中，并用此模型对涡轮机引擎的状态进行预测。文献[42]将机械数据用推理规则转化为清晰的领域知识并集成到前馈神经网络中，利用完成训练后的模型预测齿轮箱的健康状态。在此模糊神经网络组合模型中，神经网络中的学习机制和模糊推理系统中经典的语言描述都得到了运用，模糊推理系统和神经网络进行了有机结合。以上的这些组合模型的建模原理都清晰易懂，具有显著的适应性、鲁棒性和很好的柔性。

表 2-1　预测的主要技术

类别	方法	支持技术	应用领域	优点	缺点
物理模型	第一法则	残差值评估，参数漂移分析	轴承、齿轮、回转轴、飞机发动机、瓦斯涡轮压缩机	当工作状况发生改变时，不用重新搜集大量数据训练模型	模型通用性差，建模困难
	参数确定				
基于知识驱动的模型	模糊逻辑	模糊集，模糊分类规则	核能，制造车间	可以处理不准确、不清晰和不完备的信息，可以进行连续的数学建模	权重参数的确定是难点
	专家系统	领域知识，启发式规则，逻辑算符	能源转化处理，能源分配系统，制造系统	通过模拟专家的思考过程来解决问题	领域知识难以获得；同时难于将领域知识转化为规则
基于数据驱动的方法	ANN	BP，DWNN，PNN，SOM	轴承、齿轮箱、能源系统、飞机发动机、齿轮盘	适用于解析困难的模型，可以进行准确的在线模式识别	难以将领域知识应用在 ANN 中；操作环境改变后需要搜集大量数据重新训练模型；黑盒子系统
	贝叶斯网络		轴承打孔机零部件	理论基础监视，容易实现对未来状态的预测	需要大量历史数据，特别是失效数据

续表

类别	方法	支持技术	应用领域	优点	缺点
基于模型驱动的方法	状态空间模型	HMM，SHMM	液压泵、飞机系统、钻孔系统	揭示了隐藏状态的转换过程，易于编程实现	HMM 的前提在实际应用中不太实用，HSMM 减少了 HMM 中的限制，但是相对比较复杂
	失效率，部分失效率模型	统计方法，如最大似然估计	涡轮、泵	通用性强，模型不需要做太多前提假设	因为“修复如新”维护理论，应用受到限制
	灰色模型	GM(1,1)	制造过程，电力系统	处理不完全信息，擅长处理时间序列数据	新引入设备健康预测领域，需要更多的实践应用

文献[119]比较了应用循环神经网络的系统和应用模糊神经网络的系统，对两个系统各自输出的故障传播趋势预测结果进行了比较。通过比较，发现在训练良好的情况下，模糊神经网络系统在预测的精度和训练的有效性方面均优于仅使用神经网络的系统，模糊概念的引入提高了系统的性能。Chinnam 和 Baruah[68]也使用了模糊神经网络模型来预测有效剩余寿命，该模型在不能获得失效数据和对特定的失效模式缺乏定义时，可使用来自领域专家的有效经验知识来估算设备的有效剩余寿命。Satish 和 Sarma[143]将模糊逻辑理论融入反向传播神经网络中，对轴承状态建模，用于判断发动机当前状态和预测有效剩余寿命。文献[144]将模糊数学模型和 RBF(radial basis function)神经网络模型结合，用来预测烧煤锅炉潜在的故障。Kothamasu 和 Huang[145]设计的设备诊断预测模糊神经网络模型建立在 Mamdani 模糊学习模型的基础上。这个清晰度高、鲁棒性强的建模系统作为辅助决策的角色，很好地服务于 CBM 过程中。该系统着重强调了自身的清晰性和易解性，因此它能够作为辅助决策有效地服务于领域专家，并且当一些常见的变动发生时，可以很容易地对系统进行相应的修改，甚至通过与用户的互动实现持续的更新和升级。当系统中的规则改变时，模糊神经网络系统的易理解度通常会降低，Kullback-Leibler 信息法则被引入系统中来解决这个问题。该法则可以评价并规范改变后的规则，使系统更容易解释和理解。

灰色模型 GM(1,1)非常擅长处理时间序列相关的问题[146]，而人工神经网络

和大多数别的方法则具有更强的非线性时间序列的处理能力。文献[147]将灰色模型 GM(1,1)和反向传播神经网络结合,设计了一个基于多状态参数的模型来预测发电站中设备的健康状态。通过充分利用操作数据,对数据进行提取分析后,能够使用状态监控数据和统计操作数据预测设备的健康状态。与使用单特征参数的预测模型所输出结果相比,该组合模型的结果更具合理性。

还有其他一些混合模型也被用于设备健康状态预测领域。文献[148]为飞机辅助动力装置中的组件设计了一个性能退化模型,该模型对系统在未来时间内将会持续经历的健康状态做出了完整的预测。这个多变量状态空间模型包括一个年龄结构的退化状态分布、组件间的相互作用、设备维护技术员的维护动作和突发性损坏等离散性事件对系统造成的影响。Mohanty[149]为飞机中的金属架构组件设计了一个可进行实时的有效剩余寿命预测的组合模型。该预测模型的结构包括了离线的物理基础信息、离线的数据挖掘模式和在线的系统判别三部分。在离线预测部分,模型输入空间的训练数据采用对疲劳裂缝成长造成影响的参数。当进行在线预测时,输入空间的训练数据选取的特征值提取自压电传感器信号,而没有采用在实际飞行条件下很难测量的负载参数。训练完成的高斯过程模型的输出空间,包含了对相应的未知裂缝的长度和损害状态的预测。

另外,Zhao 等人[150]提出了用随机组合方法进行高效的齿轮健康预测。基于广义多项式,这种方法被用来评估齿轮剩余使用寿命预测及贝叶斯推理的似然函数的不确定性。收集的状态监测数据被集成到预测模型中,通过贝叶斯推理出更新的在给定的检验时间的不确定性的分布。与传统的模拟方法相比,所提出的方法是更有效的,并且能够处理高维概率空间。可用实际算例来证明所提出的方法的有效性。文献[151]首先介绍了在线时间序列预测模型的预测应用。根据采集到的大量操作数据、经营采样数据,可以预测系统状态的未来发展趋势和可能的系统故障。本研究提出一种新的方法,包括五个改进的在线支持向量机,实现自适应的在线状态监测与故障预测。文献[152]首先设计了一个退化失效的模式判别模型,应用此模型联合一类支持向量机算法获得非线性自适应故障阈值。随后,提出了一个基于非参数核估计的动态概率模型,来评估性能退化数据的条件概率分布。超过该自适应故障临界值的概率分布被视为可靠性指标,优点在于其可以被用来估计没有大量的经验资料和实验数据的单个设备的性能可靠性。同时,支持向量机算法在设备预测诊断领域也具有很好的表现[153,154]。

2.4 设备维护方法的研究及进展

企业设备的维护决策有助于企业按时完成经营目标，提高设备的利用率和效能，运用各种维护技术和措施，在使用过程中对设备进行维护与修理、改造与保养。设备维护具有广泛的研究领域，并且与现代的企业生产和工程管理的发展具有密切的关系。随着现代科技的发展，企业的设备也变得更加复杂，对设备的维护要求也越来越高。随着设备现代化水平的不断提高，维护主要分为以下四种。

(1) 事后维修(corrective maintenance，CM)。是指当设备发生故障，或者在设备进行日常的停机检查时发现故障，对设备采取的维护方式。CM 的主要目的就是去除设备当前遇到的故障。在初始的产业革命时期，当时的工业生产规模小，发生故障的后果一般并不严重，设备故障的影响仅局限于设备自身，为了提高设备的使用率，降低不必要的维护产生的损失，可以采用 CM。随着设备复杂性和科学技术的发展，CM 已经不能满足当前的维护需求。

(2) 预防性维护(preventive maintenance，PM)。是指对设备故障以预防为主要目的，对设备进行检查和检测，防止设备故障发生，在设备的故障征兆被发现后，采取不同的维护决策，使设备保持在初始的功能状态。目前，在当前的企业生产过程中，PM 是一种常见的预防故障发生的方式，也是一种常见的维护方式。

(3) 状态维护(condition based maintenance，CBM)。表示设备的故障从开始发生到发展总有一段出现异常现象的时间，而并不是瞬时发生的，状态维护是指在设备故障出现前找到故障迹象，预防其发生所采取的各种维护活动。利用日常检查、状态连续监测、设备故障诊断所获得的信息，通过数据统计分析，有效地判断恶化程度，在 CBM 过程中，设备的运转时间没有进行明确的规定，对于设备健康预测的有效利用，防止了 CM 的维修不足及 PM 的维修过度，是企业生产中最经济、合理的维护决策方式。

(4) 以可靠性为中心的维护(reliability centered maintenance，RCM)。在系统进行维护时，可对其他没有发生故障的设备进行可靠性的检查，预先发现设备的故

障征兆，而且不会造成多余的停机。是一种预防设备故障重复发生，降低设备停机时间的基于可靠性的维护方式。

基于上述分析与归纳，获得目前常用的四种维护方式的分析结果，如图 2-4 所示。

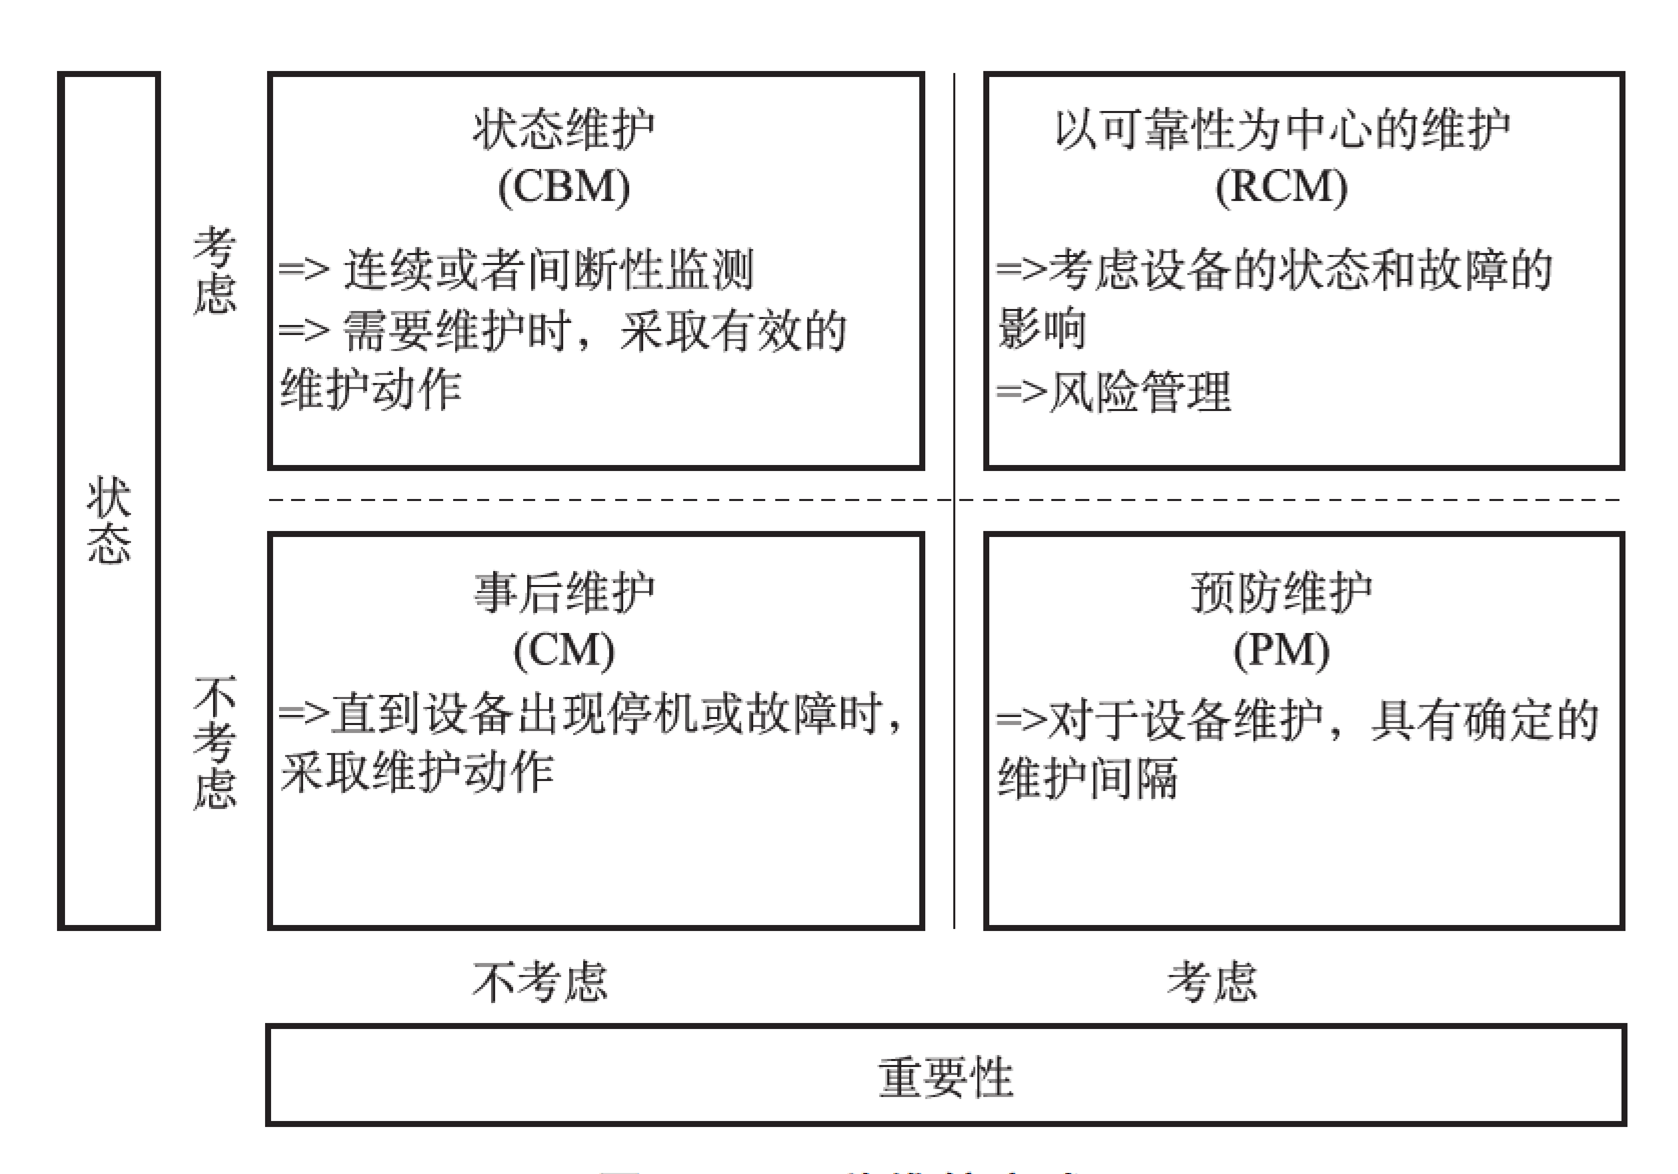


图 2-4　四种维护方式

企业在执行设备的维护计划时，在很多情况下都需要对多种维护策略进行有效的合理组合，而不是仅仅采取一种维护策略。并且，还需要考虑在执行维护策略后的设备性能状态。通常设备的维护策略主要有以下三类。

（1）小修（minimal maintenance）。对设备采取小修策略，能够恢复设备的功能，但是无法改变设备的故障状态。在设备小修后，设备的故障发展趋势不变。

（2）大修（imperfect maintenance）。对设备采取大修后，对于设备的故障率会发生变化，但是，设备无法修复到其最初的状态。

（3）置换（replacement maintenance）。对设备采取置换后，设备将修复到最初状态，并且，设备的运行特性会重复上一个周期的运行特性。

有效合理的维护策略可以保持设备持续有效的运转，因此，设备的维护策略得到了极大的发展，并且，这一领域的内容也获得了深入的研究，根据不同设备的不同维护需求，建立了多种合理有效的维护策略模型，在企业生产中也得到了广泛的应用。

2.4.1 基于健康信息的维护

预测的目的就是要为维护方案的制订提供决策支持[15]。因此，很自然地，需要在设备状态预测的过程中考虑下一步的维护方案。上一部分总结的设备寿命预测的方法提供了设备剩余寿命的估计，而维护规划是在此基础上进一步确定恰当的执行维护的时间。可见，比起寿命预测，维护规划更直接地决定了维护策略的有效与否，更直接地影响了一个企业的产能。但是，维护规划问题往往较寿命预测更为复杂。总结目前相关文献，一个预防维护规划模型一般包含五大因素：

（1）目标，维护费用最小化，维护费用率最小化，系统平均可用度最大化等；

（2）维护方案，刻画了维护执行的特点（框架），如周期性维护、顺序型维护、控制限度维护等；

（3）维护质量（或维护效果），刻画了维护行动将设备性能提升的程度，有修复如新、修复非新、修复如旧等；

（4）退化模型，刻画了设备退化的过程，有传统的寿命分布、Gamma 过程、马尔可夫过程、实时状态监测变量模型等；

（5）维护限制，如部件间的维护冲突、维护备件有限等。

以下总结近年来主要的相关模型。基于状态监测的维护规划模型分类方法多样，例如，Jardine 等人[15]将之分为完全可见系统和部分可见系统。其中，对于完全可见系统，状态监测变量完全体现了系统的真实状态；对于部分可见系统，状态监测变量不能完全体现系统的真实状态，但与之相关。

对于基于设备健康信息的维护决策方法，文献[155,156]建立了基于状态检测的单设备的可靠度维修决策模型，用最小化的期望费用为模型的优化目标，应用混合概率的模型来刻画恢复非新的 PM 效果。文献[157]建立了基于状态检测的多设备的维修决策模型，模型考虑了维修的限制约束条件，以最小化系统寿命周期内的维护的总成本为优化目标。因为多设备之间的相互关联，单个设备的最优维修策略并不代表整体的最优维护策略，所以，需要建立系统级别的维护决策模型。在文献中，假设多设备系统的失效概率是已知的，没有考虑系统在实际运行过程中的状态是不断变化的这一情况。同文献[157]相同的研究还见文献[158]。

文献[159]主要研究了状态维护，在维护过程中，对期望总费用率进行最小化，设备的修复如初也被考虑，通过获得设备的检测信号，建立了状态空间模型。在模型

中，循环算法被用来预测设备的振动信号，从而获得设备的故障概率。文献[160]也同样采取了这一方法对设备执行维护决策。文献[161]建立了在线自适应状态的维护决策模型，而且应用状态监测数据对机械设备进行维护决策。

文献[162]假设设备失效概率既依赖它的工作时间，同时也依赖一个诊断随机过程，用 PHM 来描述系统失效概率，借以构建一个替换优化策略来最小化系统长期期望的总费用率。Tran 和 Yang[163]提出了一个基于设备状态信息的维护策略。其中，基于机械系统的预测信息，进一步使用 PHM 估计系统的可靠性，在此基础上建立一种新的智能 CBM 对旋转机械系统进行维护。在文献[164]中，一种基于状态检测的替换优化策略被研究，主要目的是对系统的期望总费用进行最小化，PHM 被用来对系统失效率进行估计；同时，假设系统的检测状态符合非齐次马尔可夫过程，从而来估计系统失效概率，最终获得系统最优的维护限度。基于周期监测的替换优化模型，文献[165]最小化系统的长期期望总费用率，考虑了检测变量是间接地对系统的状态进行描述，并且，与系统的状态随机相关，用 PHM 来估计系统失效概率，从而构建系统的费用率优化模型。同样，文献[166-169]也提出了基于 PHM 的替换优化策略。

Wang[170]通过贝叶斯理论融合了来自几个传感器的状态数据，计算一个隐含状态的后验概率分布，然后，将该后验概率值与预先设置好的阈值进行比较，确定设备是否需要维护。考虑了多变量贝叶斯控制图的设计，计算状态之间的转移概率和监测信息间的关系，蒙特卡洛仿真用于获得最优的监测间隔，为设备提供最优的维护策略。基于监测过程积累的知识，Elhdad[171]提出了一种新颖的架构和设计，以提高维护决策。监测过程是基于在核电厂的安全关机过程中被触发的信号。为了提高维修的决策，延长本体和框架确保决策者有足够的信息在正确的时间做出正确的决定，Horenbeek 和 Pintelon[172]提出了一个系统动态预测维护策略，以单位时间的平均长期维护成本为目标，利用系统的预测信息和系统内部不同元件之间的依赖性，对系统采取最优的维护决策。Guo 等人[173]提出了一个 Wiener 随机过程的模型，处理任务导向系统的逐步衰退过程，制定相应的维护策略。对于一个以任务为导向的系统，任务通常具有可用性/可靠性、维修动作的机会、监测类型（连续或离散）的约束。基于设备的可靠性信息，Zhao 等人[174]应用一个标准的累积损伤模型来执行维护计划，确定在故障发生前，设备可以得到充足的维护。同时，随着维护技术的发展，也出现了相应的维护管理平台，并且，针对维护管理平台的缺陷，提出了相应的改进措施[175]。

2.4.2 基于衰退过程的维护

针对基于设备衰退过程的维护决策方法，文献[176]建立了基于状态监测的备件订货—替换决策模型，模型考虑了维护的备件需要提前预订，假设设备在使用中符合衰退增量是单调递增的随机衰退模型，在每个时刻，增量之间是相互独立的，并且，统计分布是相同的。在文献[176]的基础上，文献[177]考虑了设备失效阀值的不确定性这一情况，文献[178]考虑了基于 Markov 衰退过程的预防替换优化模型及新的库存机制。文献[179]构建了一个新的随机过程(伽马进程)，用来描述设备衰退过程，还考虑了设备健康状态的概率分布，最终来确定设备维护策略。同样，文献[180]也提出了一个性能衰退系统的维护决策模型。

文献[181]建立了基于状态检测地 PM 模型，以最小化的期望成本为优化目标，在 PM 模型中，假设系统可以被完全修复，并且，如果系统的状态值达到设定的阈值时，PM 被采取。文献[182]延续了这部分研究工作，建立了一个由两个串联设备组成的系统级的维护决策模型。在这部分研究基础上，文献[183]考虑了设备修复非新这一情况，并且假设修复后设备的健康状态随机地处于修复前与全新的健康状态之间。同样类似的研究见文献[184]。

文献[185]建立了基于状态检测的替换优化模型，并且，在某个时刻点的设备故障概率可以用随机参数的增长模型进行估计，监测区间及最优的维护限度根据模型被确定，提高了设备的可靠性。文献[186,187]提出了基于状态检测的漂移衰退过程的维护优化策略，以最小化某段时间的平均维修费用为目标，将整个漂移衰退过程划分为(N+1)段，用 Markov 过程进行建模，采取控制限度的维护优化策略，获得了最优的监测时间间隔和最优的维护时间。文献[188-191]提出了基于状态检测的随机衰退系统的替换优化模型，获得设备的最优维护的阈值及最优监测的时刻点，提高了设备的利用率，并且，假设系统状态的衰退在所有时刻都是非负的，已知系统的状态衰退的增长程度概率密度函数及确定性的失效阈值，来估计系统某时刻的失效概率。此外，文献[192]考虑了两种系统失效情况：系统累计损伤和应力环境条件下的系统冲击，从而来优化系统的期望总费用率。

文献[193]考虑了设备状态衰退具有非单调的特征，在设备监测过程中，受环境因素的影响，用替换优化模型来优化设备的总费用率，并且用 PHM 来描述环境因素对设备状态的衰退影响。文献[194]考虑了多设备系统的维护情况，文中假设系统受到来自外界的随机性冲击，如果在使用中，设备的累积损伤达到某个阈值时，设

备会发生故障。从而,对系统进行 PM 决策,在维护过程中,通过计算优化该阈值来最小化系统的长期期望总费用率。文献[195]建立了一种接受连续性监测的单设备系统的 PM 模型,并且寻找最优的控制限度来最大化该系统的平均可用度,根据随机衰退优化模型来计算系统失效概率。在文献[196]中,预测性维护策略被发展,通过对系统进行实时监测,来自传感器的在线衰减信号被用来对系统衰退模型进行更新,从而对系统的剩余寿命有效预测进行更新。

Nevesa 等人[197]结合优化模型和来自经验数据的输入参数估计,提出基于状态的维护策略。通过离散状态下令状态从"新"到"完全失效"来描述设备的退化信息,主要目的就是提出一个执行最优维护策略的算法,对于模型参数估计发展一个递归程序。为了充分利用分析和仿真模型的优势,Kahrobaee 和 Asgarpoor[198]提出了一个混合仿真分析的方法,解决实际系统的维护优化问题。在这种方法的第一步中,使用半马尔可夫决策过程获得风力涡轮机的最佳维护策略。然后,蒙特卡罗仿真建立模型和求解模型,对得到的结果与仿真模型的识别结果进行了比较。在第二步中,对系统可用性和成本产生影响的保养与维修效果,以及系统的退化信息,使用仿真模型进行了研究,开发的模型可以帮助资产管理者进行合理的维护决策。Len 和 Tan[199]研究了一个退化系统的维护策略,每个退化水平都可以用一个状态来表示,因此,系统变成了一个多状态系统。在许多情况下,对于系统的状态没有明显的症状,只能通过彻底的检查来了解系统的退化程度。通过状态监测,不确定性的系统状态可以被估计,然后根据监测的退化状态,安排设备的维护策略。

2.4.3 基于备件库存的维护

设备的备件是设备维护的重要资源。因而,备件的库存管理成为设备管理中十分重要的内容,可以保障设备高的可靠度,同时,备件库存需要占用大量的企业流动资金,从而影响了企业的经济效益。为了快速地满足市场的需求,减少备件缺货所造成的设备停机损失,必须预测备件需求,进而采用合适的备件库存策略。过去对备件库存的学习主要集中在库存策略的优化与应用,怎样在确保一定的服务水平或总成本最低的情况下确定库存水平等方面。

预测性维护可提供当前或预测系统的健康状况,并使用预测信息启动维护行动。预测性维护的研究涉及备件库存管理、维修策略优化和评估。目前,已建立的数学模型可用来描述考虑备件库存预测性维护[200-203]。

Basten 等人[204]设计了一个最佳的解决算法，进行设备维护和备件库存的联合优化。Huynh 等人[205]在考虑设备备件的基础上，研究了以最小的单部件可修系统的维修次数为目标的设备维修保养策略。Wang[206]构建了一个联合的备件和维修检查的优化模型，使用延迟时间的概念描述设备的故障过程，其中故障过程被分为两个阶段，考虑了三个决策变量的联合优化：订货量、订货间隔和检查间隔。Wang[207]提出了备件库存控制和预防性维护检查间隔的联合优化。所有这些研究都涉及设备的维护和备件库存的联合优化。

在文献[176]中，基于设备的状态监测，一种订货—替换模型被提出，在提出的模型中，维修所需要的部件要提前进行预订这一情况被考虑进去。基于设备的剩余有效寿命估计，Rausch 和 Liao[208]讨论了联合生产与备件库存控制策略，并且采取状态维护的方式。退化信息用于启动更换行动，配合备件库存控制，同时，以生产批次大小和到期日期作为限制条件。Elwany 和 Gebraeel[209]提出了一个设备剩余有效寿命和备件库存决策模型的衰退模型框架，用来自已有的置换元件的状态检测信息获得设备的剩余寿命分布。还有另外关于备件优化的文献，在这些文献中，主要关注点是备件的优化问题而不是设备的维护问题。Lin 等人[210]考虑了满足设备维护的备件的存货水平点，每台机器都包含相同的重要组成部分，并且用马尔可夫过程描述这些元件的衰退行为。在系统的运行监测过程中，Louit 等人[211]建立了一个模型来确定备件的订货决策。Li 和 Ryan[212]提出了一个新的模型，在模型中，将实时状态监测信息集合到备件库存管理决策中，并用退化模型推导出一个正常运作的部件的寿命分布，用以估计备件的订货需求。Khanh Nguyen 等人[213]通过马尔可夫决策过程研究了在技术变革下备件库存对设备维护和更换策略的影响。更换决策的制定是一个复杂的过程，需要确定取代当前设备的技术是可行的。详细的关于备件库存和设备维护之间的关系，可以看综述文章[214]。

2.5 设备维护调度方法的研究及进展

自 20 世纪 30 年代起，在现代工业的生产中，设备管理越来越重要。设备管理主要是以将设备效能进行最大化、生产需求最优化、经济效益最大化为目标，通过

各种先进的管理技术和有效措施，对设备进行采购、装配、维护、改装及更新的寿命周期的全过程的管理。目前，对于维护调度技术的研究仍然处于初级阶段。设备的维护调度优化是联合维护管理思想的具体体现。

本书的研究对象液压泵是一类复杂多部件的设备，对于这一类设备，在维护过程中，如果设备的部件之间在结构、故障、经济上都不具有相互关联性时，说明每个部件是相互独立的，对每个部件采取的维护策略也是相互独立的，每个设备部件的最优维护策略构成了整个设备的最优维护策略。对于多部件设备，在对某个部件进行维护时，除了考虑自身的工作状态外，还要考虑其他部件具有的工作运行状态。比如，当设备中某个部件发生故障，需要采取维护活动时，设备进行停机，在这个过程中，对设备中的剩余部件也采取相应的维护活动，虽然它们可能没有发生故障，或者没有达到它们的维护时刻，但是，同时维护可以有效地降低整个设备的维护成本。

对于多部件设备的维护内容，当前的研究还不是太多，目前，常用的两类维护建模为：①考虑设备劣化是连续的随机过程时，对设备进行建模。②考虑设备劣化是离散的随机过程时，利用马尔可夫链理论，发现设备劣化的规律，在劣化过程中，当达到某一阈值时，采取对应的维护活动。文献[159]对一般混联的多部件设备维护决策的问题进行了研究，利用马尔可夫链的思想，建立了系统的视情维修策略。文献[160]建立了多元件系统的 PM 策略模型，在对系统进行维护的过程中，考虑环境因素对设备的影响。在文献[161]中，对多部件且并联系统执行维护调度，以期望成本的最小化为目标。文献[162]研究了多部件设备制造系统的生产与 PM 问题，建立了双层的优化模型。文献[163,164]都对并联的多部件设备系统进行了维护决策建模，分析了并联系统的维护策略。

对于多部件设备的维护是不同于单部件设备的维护的，主要是因为多部件设备存在相关性[165,166]。多部件设备之间具有经济相关性、结构相关性和随机相关性。在一个时间段内对多个部件同时采取维护活动，与分别对设备中的单个部件采取维护活动相比，会更加节省维护费用，这就称为系统经济相关性。在整个设备中，有并联、串联和混联三种方式，当对设备中的某个部件进行维护时，会产生其他部件的停机，这就称为设备结构相关性。在设备的部件间，出现的故障是不独立的，相互影响的，这就称为设备随机相关性。所以，在维护决策时，为了更加满足设备的实际情况，在维护过程中需要考虑设备的相关性。目前，多部件设备的维护策

略主要有以下两种。

1. 多部件设备的成组维护

成组维护是指在同一时刻对设备中不同部件进行维护,以保证部件的可靠性或降低设备运行成本的维护策略。成组维护具有三个研究方向[167],第一个方向是:对部件根据依赖因素进行分类,可同时进行同类部件的维修。第二个方向是:考虑部件的备件,对设备总的维护成本进行优化。第三个方向是:对具有相同的故障分布,并且独立运行的部件进行维修。

在一些复杂设备中,常存在一组相同类型的部件在相同的使用条件下进行工作的情况。多部件设备成组维护策略表示某一部件发生故障,并进行维护时,其他的同类型无故障的部件一并进行维护,包括 T 成组维护策略、m 成组维护策略及 (T,m) 成组维护策略[168,169]。T 成组维护策略表示指定役龄成组的更换策略。也就是说,当系统的役龄到达 T 时,对于所有相同的设备一并进行更换。m 成组维护策略描述了基于故障数量的成组维护策略。也就是说,当多部件系统出现了 m 次故障时,采取成组更换。(T,m) 成组维护策略表示将以上的两种策略进行组合,当多部件系统达到了使用时间 T 或者系统出现了 m 次的故障后,采取成组维修。文献[170]对一组具有同样的指数使用寿命分布的设备建立了成组维护策略。针对系统的全面检查,可获得系统中发生故障的设备数,并依据发生故障的设备数来决定是不是对系统采取成组维护。Liu[171]对 M 个相同设备(可能发生随机故障)建立了一种优化的成组维护策略,并引入了四种设备健康状态:状态好、状态可疑、应该进行 PM 和失效。针对生产设备服从一般的正常寿命分布的情况,构建了一个估计优化模型来区分四种健康状态,且假设好的状态和可疑的状态的持续有效时间服从指数分布。文献[172]对一组设备故障时间服从 Weibull 分布的相互间独立的多设备生产系统,建立了成组维护策略。其优化的维护计划不但能满足设备的可靠度要求,还能最小化设备总的维护费用。文献[173]对 k-out-of-N 的系统采取成组维护策略的情况下,还对维护间隔、维护备件和维护能力对系统的可用度影响进行了研究。文献[174]对复杂系统的维护费用的构成和系统的利用率进行了分析,并且用故障风险作约束,用最小化系统的总维护费用以及最大化利用率作为优化目标,提出了系统的维护策略优化模型。文献[175-178]也对成组维护策略进行了有益的探索。文献[179]针对随机发生故障的一个制造系统,研究生产调度过程中如何有效地控制设备 PM 和故障维护的问题,以设备的维护成本、设备库存

成本及生产延迟成本最小化为优化目标，通过优化算法对模型进行了分析，从而制定最优的库存控制策略，同时，对该策略的应用以及后续扩展问题进行了讨论。

2. 多部件设备的机会维护

机会维修是指当设备运转时，因为某个部件发生了故障或者进行维护需要停机，而其他没有发生故障并且役龄满足预定条件的部件因此获得了维护机会可以提前采取维修的维护策略。机会维护最先是由 Radner 等人[180]和 McCall[181]进行研究。根据系统配置形式的不同，已有多种机会维护策略被提出。

Berg[182]研究了具有指数故障率分布的两台相同设备的机会维修策略：当一台设备出现故障时，采取维护措施；对于另一台设备，如果使用寿命大于其阈值，需要同时采取维护措施。Laggoune 等人[183]提出了一种多元件串联系统的机会维修替换策略，以不确定的数据为背景，在设备寿命分布确定后，以单位时间的期望成本为目标，对故障进行维修。故障设备被修复，同时其他设备被保养，这样所有部件都被维修且恢复为某一个健康状态。文献[184]建立了一个多部件设备累积的故障冲击优化模型，且建立机会维护策略模型。维护策略根据每台设备故障的时间点来决定。且每次出现故障时，采取维护策略进行维修，而且，对于其他的部件进行保养维护，因此所有部件都被维修且恢复到某一个健康状态。这种维修组合采用 CM 和 PM，有利于维修成本的节约。文献[185]应用机会维护策略将 PM 和故障维护有机地结合起来，进而可以分摊系统固定的维护费用，达到节约维护费用的目的。

文献[186,187]研究了不同设备所组成的串行的生产系统，并且用引入了整合役龄的递减因子及故障率的递增因子单设备 PM 模型，构建了基于各设备的可靠性的串行系统的机会动态维修决策模型。文献[188]研究了多元件系统的机会维护策略，把多元件系统分解为单元件系统，用马尔可夫决策过程对每个单元件系统进行维护调度建模。文献[189]提出了一个基于 CBM 的生产系统的动态维护调度模型。文献[190]提出了一个优化的粒子群算法，对电力系统进行维护调度。与机会维修相关的其他模型可以参考文献[191－195]的综述。

对于维护调度的方法汇总如图 2-5 所示。

维护优化模型

种类	方法	应用领域	优点	缺点
优化模型	启发式优化算法	生产系统，电力系统等	具有较低的计算时间和计算复杂性	不能实现多目标的运算
	混合优化	电力系统，调度问题等	联合了两个及以上算法的优点	不能消除每种算法的缺点
	多目标优化	服务领域，多目标领域等	可以实现问题的多目标运算	具有高的复杂性和计算时间
	遗传算法	工程领域，制造领域等	计算结构简单，可以获得理想的优化结果	容易陷入局部最优解
	模拟退化算法	交通系统，生产系统等	可以优化解决许多联合问题	选取参数较困难，具有高的运算时间
仿真模型	蒙特卡洛仿真	工程领域，生产领域等	具有较大的灵活性，可以分析不同的策略与参数	不能获得简单的计算方程，不能得到确切的解决方案
	离散事件和连续仿真	服务领域，医院资源优化等	可以发展更优化、更灵活的模型	没有考虑真实系统的有效性，不能获得确切的解决方案
数学规划模型	动态规划	资源配置，风险管理等	储存记忆，有助于解决多阶段问题	空间复杂性较高
	整数规划	调度问题，生产系统等	有助于求解一些复杂问题	很难界定一个特定的目标函数，很难估计各种系数
	分支定界	调度问题，生产系统等	有助于发现问题的最优解	后代数量巨大
	分型方法	制造领域，交通系统等	针对于较大的数据，增加了识别精度	考虑因素较多，限制了应用范围
基于知识的模型	专家系统	制造领域，电力系统等	利用专家知识解决问题，考虑了人的因素	很难获得专业知识，和将知识转化为规则
	模糊方法	制造领域，电力系统等	可以处理模糊问题和缺少数据的问题	难于对权重进行分配

其他模型	联合模型

图 2-5　维护调度的方法汇总

2.6 现有方法的不足

随着企业设备维护调度的重要性日益增加，为了实施符合企业生产的维护调度策略，有效提高企业的生产效率，实现企业的全部效能，发挥设备的先进性，必须进行设备的健康预测；基于设备健康状态的预测信息和衰退性能，建立完整的设备集成动态维护策略。然后，结合设备的集成动态维护，实现多部件设备的维护调度优化。但是，当前的设备健康预测、设备维护和维护调度优化显得有点薄弱，因此，基于上节的文献综述，本节指出一些值得研究的问题。

2.6.1 设备健康预测研究的不足

为了保持企业生产设备高效安全地运转，需要及时有效地进行设备的维护，以便提高企业的竞争力。如今，随着生产要求的提高，提高设备的可靠性成为突出问题。同时，随着市场竞争的加剧，企业对设备的可靠性、安全性和有效性要求更高。基于这些事实，合理有效的维护决策就变得十分重要，可靠精确的健康预测，为进行合理有效的设备维护提供了基础。

基于 2.2 节的内容，针对健康预测的方法存在的许多问题，对物理模型来说，在不需要大量同类设备的历史数据的情况下，也可以实现模型的较精确的预测。然而，在进行预测时，需要对设备进行停机监测，在实际的生产过程中，这是不经济的，也是不允许的。同时，针对当前的一些复杂设备，很难建立完整的物理模型。基于数据驱动的设备健康预测方法具有两个比较大的缺陷：非常慢的收敛性及容易陷入局部最优解。由于数据驱动的原因，这些模型具有很高的计算复杂性，容易造成计算爆炸问题，这些缺陷限制了方法的应用和发展。基于模型驱动的设备健康预测方法的识别和训练过程需要耗费较长的时间，不适合设备实时的健康预测。因此，这类模型常用于离线设备的健康预测。

合理建立在线设备健康预测非常重要，基于对设备健康预测相关文献回顾后发现的不足与局限，本书根据 SMC 方法的在线特性，以及 HSMM 的数学特性，将两种方法进行拟合，SMC 用于降低模型的计算复杂性，HSMM 用于识别设备的健康状态，

获得状态的转移概率和状态驻留。基于这些原理，本书提出了基于设备联合概率的多步向前健康预测算法和设备健康预测模型，进一步研究设备的在线健康预测。

对于多传感器的设备健康预测，通过前面章节的文献回顾，主要存在以下三个问题：①来自多传感器的监测数据在没有有效处理的情况下，直接作为健康预测模型的输入；②来自多传感器的监测数据仅仅进行了降维处理，就直接作为健康预测模型的输入；③对来自多传感器的监测数据分配权重，每个传感器被赋予了一个权重，然后作为健康预测模型的输入。针对以上这些缺陷，本书在对 HSMM 进行改进的基础上，提出了自适应 HSMM（AHSMM），这个模型可以很好地实现多传感器之间的有效融合，进一步研究了基于多传感器的设备健康预测。

2.6.2 设备维护研究的不足

目前，设备的维护方法存在许多问题。对于一般的维护模型，设备的预测信息和诊断信息都没有被使用。对于在维护模型中使用的可靠性信息，也是来自相似设备的可靠性信息，即使对 CBM，也仅仅是使用当前的设备状态信息。对于基于设备衰退过程的维护策略，基本上是只考虑了设备的退化信息和设备的老化信息。对于基本备件库存策略的维护，也只是考虑了备件这一种资源，而没有考虑其他的维护所需要的资源。这些因素都限制了设备维护模型的发展。

因此，合理建立设备维护模型就显得非常重要，基于对设备维护相关文献回顾后发现的不足与局限，本书考虑了设备的预测信息和诊断信息、设备的衰退信息，包括将设备的退化信息和老化信息结合到设备的维护模型中。然后，不同于其他单一故障状态的维护模型，应用 HSMM 模型来识别设备的不同健康状态，获得不同状态间的转移概率和不同状态的驻留时间。对每个健康状态，发展不同的维护动作，使每个健康状态都被优化到不同的目标。针对单一的维护资源，还考虑了在设备维护过程中对维护人员的需求量，将维护人员也结合到设备维护模型中。最后，基于设备的衰退过程和维护资源，提出了一个考虑设备多故障状态的双层集成动态维护模型，第一层主要用于获得最优的资源成本和资源策略；第二层主要是获得最优的维护策略，从而进一步研究设备的集成动态维护策略。

2.6.3 设备维护调度优化需要研究的问题

目前，大多数多部件设备的维护调度都仅仅只考虑设备的可靠性数据，没有考虑设备的其他状态信息，如设备的老化与退化等。同时，完整的剩余寿命在预测性维护调度中没有表现出来。在目前关于设备维护调度的模型中，可以用修复如新

来描述设备的维修效果。也就是说,设备的维护可以让设备修复到原始的最佳状态。而实际情况是设备并不能修复如新,仅仅能获得状态的部分优化。目前,这类研究内容不多见。

针对多部件设备维护调度优化的文献分析,发现存在以下几个问题。

(1) 基于设备的维护类型。预测性维护针对性强,在设备维护过程中,具有极高的有效性和经济性。由于预测性维护需要对设备进行传感器检测、故障诊断以及寿命预测,在制定设备合理有效的维护决策时,具有一定的复杂性,同时,因为前期需要对设备进行有效监测等工作,投入的前期成本较高,所以,针对设备的预测性维护研究较少。

(2) 基于研究的对象。设备部件间的关联关系,包括并联、串联和混联三种关系。其中,混联是最复杂和最有代表性的一种互联关系,具有极大的复杂性,并且,设备部件之间的结构相关性、随机相关性及经济相关性影响极大,关系错综复杂,使模型具有复杂的求解过程,所以,对于这一类的多部件设备的维护决策研究较少。

(3) 基于研究的内容。对于设备维护的研究内容,在设备的维护决策周期、采取维护的时间点以及采取的维护方式等方面,获得了大量的研究。在研究过程中,很少去关注设备本身维护行为的具体实施,有时还假设企业的维修能力是无限的,然而,在企业的实际生产过程中,企业的维修人员、维修备件、维修能源及工具等都不是无限的,这就造成了维护策略在复杂系统中很难进行应用。所以,在多部件设备维护过程中,维护资源的调度也是不可忽略的。

对于文献中考虑多部件设备维护的分析,设备的维护周期是已知量或者假设是固定不变的,也没考虑设备发生停机时多部件间的相关性。实际上,多部件间的相关性决定了在企业制定最优的设备维护调度策略的过程中,需要将多部件间的经济相关性、结构相关性等的因素综合考虑进去。所以,本书考虑了设备多部件的维护资源及多部件间的相关关系,针对这类设备的维护调度进行优化研究。

2.7 退化隐半马尔可夫模型

HMM 的随机序列遵循马尔可夫链(markov chain,MC),一个 MC 表示一个事件序列,对于每个事件,它的发生概率仅依赖于前一事件。在 HMM 过程中,事

件是与概率函数相关，无法直接观察到的。换句话说，如果产生某个随机状态序列，相应地就会出现一个观测值向量的序列。每一个观测值向量是由一个具有相对应的概率密度分布的健康状态序列所产生，且对于每一个观测值向量，每种健康状态都被某些概率密度分布所表示。这就说明，HMM 是具有一定状态数量的隐 MC 且存在随机函数集。

对于 HMM，基本的构成元素如下。

（1）N：模型中的状态数量，对于状态，都是不可观察的，我们利用物理信号描述模型的状态。其中，对于 N 个状态，用$\{1,2,\cdots,N\}$来表示，例如，时间 t 的状态为 H_t。

（2）M：表示每个状态所对应的观测值数量。每个状态的观测特征可以表示为 $V=\{V_1,V_2,\cdots,V_M\}$，在时间 t 的观察值为 O_t。

（3）A：表示状态转移概率矩阵，表示为 $\boldsymbol{A}=\{a_{ij}\}_{N\times N}$。

$$a_{ij}=P(H_{t+1}=j\mid H_t=i),1\leqslant i,j\leqslant N$$

（4）B：表示状态观测概率的分布，$\boldsymbol{B}=\{b_i(k)\}_{N\times M}$ 表示状态 i 的观测概率分布。

$$b_i(k)=P(v_k\mid H_t=i),1\leqslant i\leqslant N,1\leqslant k\leqslant M$$

（5）π：表示初始状态分布，$\pi=\{\pi_1,\pi_2,\cdots,\pi_N\}$。

$$\pi_i=P(H_1=i),1\leqslant i\leqslant N$$

N,M,A,B 和π的定义描述了一个完整的 HMM。因此，一个 HMM 可以使用参数集 $\lambda=(\pi,\boldsymbol{A},\boldsymbol{B},N,M)$来描述。

在 HMM 中，用概率密度函数 $P(d)$来说明设备健康状态的驻留问题。$P(d)$表示设备在健康状态 i 的驻留时间为 d 的概率。因此，可以得到

$$P_i(d)=a_{ii}^{d-1}(1-a_{ii})$$

其中，$(1-a_{ii})$表示跳到另一个状态的概率，a_{ii} 表示设备停留在状态 i 的概率。然而，在 HMM 中，这种描述状态驻留时间的方式无法描述设备真实的状态驻留情况，在实际状态变化中，会出现不符合上述方程的情况。HMM 在建模中，存在以下三个实际的基本问题。

（1）评估基本问题（也称分类）：给定参数组为 $\lambda=(\pi,A,B,N,M)$和观察序 $O=O_1,O_2,\cdots,O_T$，计算出现观察序列的概率为多少（即 $P(O|\lambda)$）。

（2）解码基本问题（又称识别）：已知参数组为 $\lambda=(\pi,A,B,N,M)$和观察序 $O=O_1,O_2,\cdots,O_T$，考虑如何选择一个最优的状态序列。

（3）学习基本问题（也称训练）：如何调整模型参数 $\lambda=(\pi,A,B,N,M)$，

使$P(O|\lambda)$最大化。

对于处理 HMM 的基本问题。最直接的方法是枚举法，换句话说，就是直接列举每种长度为 T（观察值的数量）的状态序列。这种方法具有极大的计算量，并且，也无法获得全局最优解。所以，针对 HMM 的分类问题，基于动态规划模型，有些研究提出了前后向算法[228,229]。HMM 的解码目的是发现状态序列，这些状态序列是与 HMM 相对应的，在已知观测序列时，发现单个的最佳状态序列是 HMM 最常用的优化准则，因此，为寻找最优的状态序列，有学者基于动态规划理论，提出了 Viterbi[230]算法。对 HMM 的学习问题，可使用迭代算法 Baum-Welch 算法[231]来调整模型的参数 $\lambda=(\pi,\boldsymbol{A},\boldsymbol{B},N,M)$，实现 $P(O|\lambda)$的最优化。

设备在持续使用过程中，会经历一系列不同的健康状态，最终到达其故障失效状态。例如，液压泵的使用过程显示，液压泵在运转过程中，有如下四个过程：好、中等、较差、恶劣。因此，对于一台正在使用过程中的设备，对于它的健康状态，会经历 n 个不相同的健康状态：h_1（健康状态 1），h_2（健康状态 2），…，h_{n-1}（健康状态 $n-1$），h_n（健康状态 n）。h_n表示设备完全失效。设备停留在健康状态 h_i 的状态驻留时间为 d_i，设备的全寿命长度为 T。则

$$T=\sum_{i=0}^{n-1} d_i$$

与 HMM 中，状态只产生一个观测值相比，在 HSMM 中，状态将产生一个片段（Segment）的观测值，称 Segment 为 HSMM 的宏状态。对于每个宏状态，具有相应数量的单状态，称这些单状态为 HSMM 的微状态。假设 HSMM 的状态演化过程中，包含 n 个宏状态（片段），在第 i 个片段结束时的时间指针用 q_i 表示（$1\leqslant i\leqslant n$）。图 2-6 描述了宏状态、微状态、状态的驻留时间及其相互之间的关系。

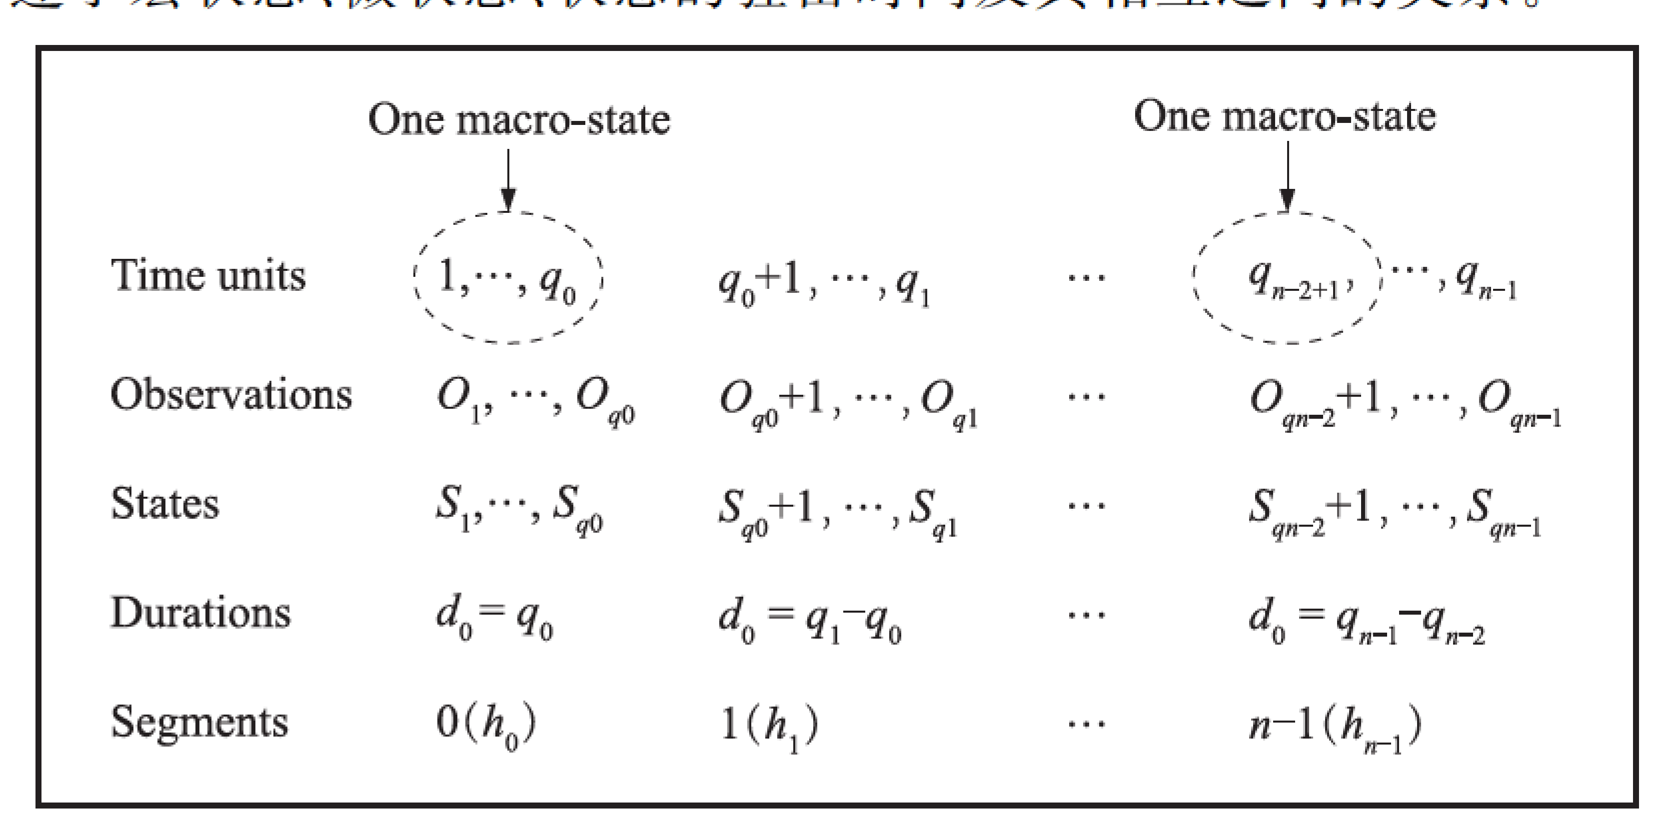


图 2-6　HSMM 中状态间的关系

针对模型中的第 i 个宏状态，且该宏状态的观测值为 $O_{qi-1},\cdots,O_{qi}$，基于 HSMM 的 Segment 原理，观测值都具有一样的宏状态标签，则

$$s_{q_{i-1}+1}=s_{q_{i-1}+2}=\cdots=s_{q_i}=h_i$$

假设设备在时刻 t 时的健康状态为 s_t，观测状态序列为 O。则 HSMM 中的基本参数有：初始状态概率分布π，状态转移概率矩阵 A，状态持续时间概率分布 P，观测值概率分布 B，健康状态的数目 N 和每个健康状态的观测值数目 M，对于 HSMM 来说，用 $\lambda=(\pi,\boldsymbol{A},\boldsymbol{P},\boldsymbol{B},N,M)$ 来表示它的基本结构。对于片段 HSMM，具有 N 个隐藏不可直接观测的状态。A 代表了状态间的转移概率，a_{ij} 表示状态 i 到 j 的转换概率。假设 $t=0$ 时，健康状态是 s_0，作为 HSMM 过程的开始（START）。HSMM 的宏状态 $s_{ql-1}\rightarrow s_{ql}$ 的转换是符合 Markov 过程的，即

$$P(s_{q_l}=j\,|\,s_{q_l-1}=i)=a_{ij}$$

对于微状态之间的转移（$s_{t-1}\rightarrow s_t$），并不是 Markov 过程，这就是模型是半马尔可夫（semi-Markov）的理由[232]。在 semi-Markov 中，当设备在不同的宏状态之间进行转移时，则该转换过程就是 Markov 过程。

相对于 HMM 来说，观测值 Segment 分布是对于 HSMM 的一个发展。当设备的健康状态为 i 时，对于驻留时间为 d 的观察值片段 $[o(t_1,t_2)]$ 的观测概率为 $P[o_{(t_1,t_2)}]\,|\,(i,d)\ (d=t_2-t_1)$。与 HMM 相似的是，HSMM 也具有以上提到的三个基本问题需要解决。

为了建立设备的在线健康预测模型，对 HSMM 的前向一后向算法进行了修正。首先，对于表示产生观察值 $o_1,o_2,\cdots,o_t$ 且于状态 i 结束的概率的前向变量 $\alpha_t(i)$ 被定义。

$$\alpha_t(i)=P(o_1,o_2,\cdots,o_t\,|\,\lambda)=\sum_{i=1}^{N}\sum_{d=1}^{\min(D,t)}\alpha_{t-d}(i)a_{ij}p(d\,|\,j)b_j(O_{t-d+1}^{t}) \tag{2-4}$$

其中，D 为最大状态持续时间；$b_j(O_{t-d+1}^{t})$ 为 $o_{t-d+1},o_{t-d+2},\cdots,o_t$ 的联合密度。

所以，在 HSMM 中，对于产生观测序列 O 的概率，可以表示为

$$P(O\mid\lambda)=\sum_{i=1}^{N}\alpha_T(i)$$

参考前向变量，后向变量为

$$\beta_t(i)=\sum_{j=1}^{N}\sum_{d=1}^{\min(D,t)}a_{ij}p(d\,|\,j)b_j(O_{t+1}^{t+d})\beta_{t+d}(j) \tag{2-5}$$

为进行改进 HSMM 中的变量估计，三个前向一后向变量被重新定义：

$$\alpha_{t,t'}(i,j)=P(o_1o_2\cdots o_{t'},t=q_n,s_t=i,t'=q_{n+1},s_{t'}=j\mid\lambda) \tag{2-6}$$

$$\phi_{t,t'}(i,j)=\sum_{d=1}^{D}[P(d=t'-t\mid j)P(O_{t+1}^{t'}\mid t=q_n,s_t=i,t'=q_{n+1},s_{t'}=j\mid\lambda)] \tag{2-7}$$

$$\xi_{t,t'}(i,j)=P(t=q_n,s_t=i,t'=q_{n+1},s_{t'}=j\mid O_1^T\lambda) \tag{2-8}$$

其中，$O_{t+1}^{t'}=o_{t+1}o_{t+2}\ldots o_{t'}$，$O_1^T=o_1o_2\ldots o_T$，$\phi_{t,t'}(i,j)$ 表示在状态 i 持续了 d 个时间单位后转换到了下一状态 j 的概率。

基于式(2-7)，可获得出 $\alpha_{t,t'}(i,j)$，$\alpha_{t'}(j)$ 和 $\xi_{t,t'}(i,j)$ 的表达式：

$$\alpha_{t.t'}(i,j)=\alpha_t(i)a_{ij}\phi_{t.t'}(i,j) \tag{2-9}$$

$$\alpha_{t'}(j)=\sum_{i=1}^{N}\sum_{d=1}^{D}[P(d=t'-t\mid j)\alpha_{t,t'}(i,j)] \tag{2-10}$$

$$\xi_{t,t'}(i,j)==\frac{\sum_{d=1}^{D}\alpha_t(i)a_{ij}\phi_{t.t'}(i,j)\beta_{t'}(j)}{\beta_0(i=\mathrm{START})} \tag{2-11}$$

则前向算法的基本流程为

第一步：初始化($t=0$)

$$\alpha_{t=0}(i)=\begin{cases}1\ 若\ i=START\\ \quad 0\ 否则\end{cases}$$

第二步：进行前向递归($t>0,t=1,2,\cdots,T$)，并且，$1\leqslant d\leqslant D$；$1\leqslant i,j\leqslant N$。

$$\phi_{t,t'}(i,j)=\sum_{d=1}^{D}[P(d=t'-t\mid j)P(O_{t+1}^{t'}\mid t=q_n,s_t=i,t'=q_{n+1},s_{t'}=j\mid\lambda)]$$

$$\alpha_{t,t'}(i,j)=\alpha_t(i)a_{ij}\phi_{t,t'}(i,j)$$

$$\alpha_{t'}(j)=\sum_{i=1}^{N}\sum_{d=1}^{D}[P(d=t'-t\mid j)\alpha_{t,t'}(i,j)]$$

则后向算法的基本流程为以下步骤。

第一步：初始化($t=T,1\leqslant i,j\leqslant N$)

$$\beta_T(i)=1$$

第二步：进行后向递归($t>0,t=1,2,\cdots,T$)，并且，$1\leqslant d\leqslant D$；$1\leqslant i,j\leqslant N$。

$$\beta_t(i)=\sum_{j=1}^{N}\sum_{d=1}^{\min(D,t)}a_{ij}p(d\mid j)b_j(O_{t+1}^{t+d})\beta_{t+d}(j)=\sum_{j=1}^{N}a_{ij}\phi_{t,t'}(i,j)\beta_{t'}(j)$$

$$\xi_{t,t'}(i,j)=\frac{\sum_{d=1}^{D}\alpha_t(i)a_{ij}\phi_{t,t'}(i,j)\beta_{t'}(j)}{\beta_0(i=START)}$$

则前向－后向算法的计算复杂度为 $O(N^2DT)$，其中，$D=\sum_{i=0}^{n-1}D_i$ 。

基于式(2-4)～式(2-11)，可得初始状态概率分布π，状态转移概率矩阵 A 和观测值概率分布 B 的重估公式。

$$\bar{\pi}_i=\frac{\pi_i\left[\sum_{d=1}^{D}\beta_d(i)P(d\mid i)b_j(O_1^d)\right]}{P(O\mid\lambda)}$$

$$\bar{a}_{ij}=\frac{\sum_{t=1}^{T}\xi_{t,t'}(i,j)}{\sum_{t=1}^{T}\sum_{i=1}^{N}\sum_{j=1}^{N}\xi_{t,t'}(i,j)}$$

$$\bar{b}_i(k)=\frac{\underset{s.t.O_t=v_k}{\sum_{t=1}^{T}\alpha_t(i)\left[\frac{\phi_{t,t'}(i,j)}{\sum_{d=1}^{D}p(d=t'-t\mid i)}\right]\beta_t(i)}}{\sum_{t=1}^{T}\alpha_t(i)\left[\frac{\phi_{t,t'}(i,j)}{\sum_{d=1}^{D}p(d=t'-t\mid i)}\right]\beta_t(i)} \tag{2-12}$$

对于设备健康状态的驻留时间重估公式，设备在状态 i 下的持续时间均值 $\mu(i)$ 均值和方差 $\sigma(i)$ 计算如下：

$$\mu(i)=\frac{\sum_{q_{n-1}=1}^{T}\sum_{q_n=q_{n-1}}^{T}\frac{1}{\sqrt{2\pi}\sigma}\mathrm{e}^{-[\{(q_n-q_{n-1})-\mu\}^2/2\sigma^2]}(q_n-q_{n-1})}{\sum_{q_{n-1}=1}^{T}\sum_{q_n=q_{n-1}}^{T}\frac{1}{\sqrt{2\pi}\sigma}\mathrm{e}^{-[\{(q_n-q_{n-1})-\mu\}^2/2\sigma^2]}} \tag{2-13}$$

$$\sigma^2(i)=\frac{\sum_{q_{n-1}=1}^{T}\sum_{q_n=q_{n-1}}^{T}\frac{1}{\sqrt{2\pi}\sigma}\mathrm{e}^{-[\{(q_n-q_{n-1})-\mu\}^2/2\sigma^2]}(q_n-q_{n-1})^2}{\sum_{q_{n-1}=1}^{T}\sum_{q_n=q_{n-1}}^{T}\frac{1}{\sqrt{2\pi}\sigma}\mathrm{e}^{-[\{(q_n-q_{n-1})-\mu\}^2/2\sigma^2]}}-\mu^2(i) \tag{2-14}$$

设备的健康预测包括设备的健康诊断和健康预测。健康诊断是指用数据训练 HSMM，识别出在特定的失效模式下设备的 n 个不同的健康状态。因此，本节会设计一个诊断模型用作设备健康状态的识别操作。在故障诊断方面，针对设备的每一个故障类型，建立相应的 HSMM 进行描述。除此之外，针对设备的正常状态，也有一个 HSMM 来表示。针对 n 组设备观测序列，为了描述每个设备的观测值，建立 n 个不同类型的 HSMM，其中，每个设备观测值描述了相应的状态。

在已知设备观测序列的条件下，利用 HSMM 原理，识别设备的失效状况。针

对完成训练的 n 个 HSMM,对于其中的每个 HSMM,描述相同的状态序列。根据最大似然函数的值,完成对序列的分类。在 HSMM 的故障诊断与寿命预测的示意图 2-7 中,表示了 HSMM 的训练阶段、故障诊断阶段及寿命预测阶段。

设备的健康状态转换点是将设备从健康状态 h_i转换到健康状态 h_{i+1}时的时刻点。对于进行健康状态转换点的诊断,是在设备的当前健康状态下,估计距离健康状态转换点的时间值。对于设备从 h_i 到 h_{i+1} 发生转移中对应的状态转换点,根据下列步骤进行识别:在获得新的观测值序列 $o_1,\cdots,o_t,\cdots$时,在线执行 HSMM 的 Viterbi 算法,如果状态 $s_t=h_{i+1}$是在设备当前最可能的状态序列中,在这种情况下,时刻 t 就代表健康状态转换点。

针对 HSMM 中的每一个状态序列,可以获得每个健康状态的转换点的估值。比如,针对状态 $s^{(t)}$,时刻 t 代表了健康状态转换点的位置。因此,针对设备健康状态转换点的估值,表示为

$$t'_{lc}=\sum\nolimits_{t=2}^{T}t\cdot P(s^{(t)}|O)$$

由于 $P(s_{t-1}=l|O)=\sum\limits_{t'=l}^{T}P(s^{(t')}|O)=P(s^{(t)}|O)+\sum\limits_{t'=l+1}^{T}P(s^{(t')}|O)=P(s^{(t)}|O)+P(s_t=l|O)$

可得

$$t'_{lc}=\sum\nolimits_{t=2}^{T}(t\cdot[P(s_{t-1}=l|O)-P(s_t=l|O)]) \qquad (2\text{-}15)$$

对于权重处理后的均值可以使惩罚函数 $\sum\nolimits_{t_{lc}}P(t_{lc}|O)(t_{lc}-t'_{lc})^2$ 达到最小化。其中,t_{lc}表示了状态转换点。基于 HSMM 的前、后向算法,该估计值可以被获得。

对设备进行健康预测,可以获得设备的状态变化情况以及预测设备的剩余寿命,也可获得设备的状态转换点。基于式(2-13)和式(2-14),每个宏状态驻留时间都可以被获得,则状态的持续时间为

$$D(h_l)=\mu(h_l)+\rho\sigma^2(h_l) \qquad (2\text{-}16)$$

$$\rho=(T-\sum_{l=0}^{L-1}\mu(h_l))/\sum_{l=0}^{L-1}\sigma^2(h_l) \qquad (2\text{-}17)$$

该状态持续时间的取值可以使 $\log P(S|\lambda,T)=\sum\limits_{i=0}^{n-1}P(d_n|h_i)$ 取值最大,同时满足条件:$T=\sum\limits_{i=0}^{n-1}D(h_i)$。

训练过程

振动数据(数据预处理)

特征抽取(通过小波技术)

模型参数估计(针对每一健康状态，利用健康状态训练数据对HSMM进行训练)

模型参数估计(利用设备的全生命周期训练数据对HSMM进行训练)

传感器信号

预处理

观察序列

$HSMM_1(\lambda_1)$

对数似然值计算(P_1)

$HSMM_2(\lambda_2)$

对数似然值计算(P_2)

$HSMM_n(\lambda_n)$

对数似然值计算(P_n)

分类过程(诊断)

设备健康状况=i

i=index[max(P_1,P_2,…,P_n)]

预测过程(寿命预测)

$HSMM_d(\lambda_d)$

驻留时间计算(获得在每一健康状态驻留时间的均值和方差)

根据设备当前状况及驻留时间参数预测其剩余有效寿命

图 2-7　基于 HSMM 的设备健康预测框架

2.8　本章小结

本章尝试对现有文献中研究的预测理论和技术进行了综述工作，所涉及的理论方法都服务于 CBM 系统。由于工业制造设备和系统的日益复杂，维护管理日益

显现出其重要性，维护成本也相应地大幅增长，因此服务于维护策略的能得到精确预测结果的工具引起了越来越多的关注。在其他领域，如模式识别、医疗预测等，得到成功运用的技术和方法也被引入设备预测领域中来，许多学者对这些理论进行了修改，使之更适用于工业应用。从文献的整理综述过程中可以看到三个增长明显的研究趋势。

（1）对来自传感器的数据进行提取处理后可以得到众多的诊断指标，对这些指标进行分析可以推测设备的运行状况。但没有一个指标能够完整地描述所有类型的故障。为了准确且可靠地预测设备的有效剩余寿命，必须同时综合考虑多个诊断指标，使用单参数预测模型很难充分完整地描述不同类型的故障及设备在故障中的不同发展阶段。作为非参数模型的人工神经网络，擅长处理多变量趋势的分析问题，并在多参数故障预测方面得到了众多关注，具有很好的研究和应用前景。

（2）越来越多的学者偏好设计组合模型来进行数据提取、数据处理和建模工作。组合预测模型具有信息利用充分、精度高等特点，因而受到广泛的重视，成为研究热点之一。从简单的启发式模型到复杂的采用人工智能知识的神经网络模型，各类方法都有它们自身特有的优点和缺点。从只采用单一理论或方法的模型中很难获得令人满意的结果，而如何设计一个能提供高精确度的预测结果的模型具有极大的挑战性。一个设计优秀的组合模型通常将两种或更多的技术、理论运用到对系统进行建模的工作中，这些理论的相互合作可以消除或减少单个理论的缺点，利用各个理论的优点，使模型能够更好地运作。从另一个方面来看，如何选择适当的方法并将它们有效地结合起来，使其“扬长避短”地在建模过程中互相协作，也是一个非常有挑战性的问题。目前，把不同预测方法的结果加权叠加的线性组合预测模型已趋于成熟，针对传统的非线性组合预测模型存在的不足，人工神经网络作为“组合器”被引入组合预测模型。许多研究将神经网络和其他的一些数据处理方法，如专家系统、模糊逻辑、灰色系统 GM(1,1)等，结合起来建模。通过实际数据的检验，可以看到这些组合的“黑盒子”模型能够输出比较理想的结果。隐式马尔可夫模型和隐式半马尔可夫模型是近来新被引入预测领域的方法。至今为止，如何采用隐式马尔可夫模型和隐式半马尔可夫模型进行预测的研究仍处于启蒙阶段。和其他“黑盒子”模型不同，马尔可夫链相关的模型有一个相对清晰的预测处理过程。文献[117]设计了一个 SVM-HMM 模型，将矢量支持向量机和隐式马尔可夫模型相结合来鉴别非稳定时间序列的发生，此类时间序列暗示设备正处于

显现出其重要性，维护成本也相应地大幅增长，因此服务于维护策略的能得到精确预测结果的工具引起了越来越多的关注。在其他领域，如模式识别、医疗预测等，得到成功运用的技术和方法也被引入设备预测领域中来，许多学者对这些理论进行了修改，使之更适用于工业应用。从文献的整理综述过程中可以看到三个增长明显的研究趋势。

（1）对来自传感器的数据进行提取处理后可以得到众多的诊断指标，对这些指标进行分析可以推测设备的运行状况。但没有一个指标能够完整地描述所有类型的故障。为了准确且可靠地预测设备的有效剩余寿命，必须同时综合考虑多个诊断指标，使用单参数预测模型很难充分完整地描述不同类型的故障及设备在故障中的不同发展阶段。作为非参数模型的人工神经网络，擅长处理多变量趋势的分析问题，并在多参数故障预测方面得到了众多关注，具有很好的研究和应用前景。

（2）越来越多的学者偏好设计组合模型来进行数据提取、数据处理和建模工作。组合预测模型具有信息利用充分、精度高等特点，因而受到广泛的重视，成为研究热点之一。从简单的启发式模型到复杂的采用人工智能知识的神经网络模型，各类方法都有它们自身特有的优点和缺点。从只采用单一理论或方法的模型中很难获得令人满意的结果，而如何设计一个能提供高精确度的预测结果的模型具有极大的挑战性。一个设计优秀的组合模型通常将两种或更多的技术、理论运用到对系统进行建模的工作中，这些理论的相互合作可以消除或减少单个理论的缺点，利用各个理论的优点，使模型能够更好地运作。从另一个方面来看，如何选择适当的方法并将它们有效地结合起来，使其“扬长避短”地在建模过程中互相协作，也是一个非常有挑战性的问题。目前，把不同预测方法的结果加权叠加的线性组合预测模型已趋于成熟，针对传统的非线性组合预测模型存在的不足，人工神经网络作为“组合器”被引入组合预测模型。许多研究将神经网络和其他的一些数据处理方法，如专家系统、模糊逻辑、灰色系统 GM(1,1)等，结合起来建模。通过实际数据的检验，可以看到这些组合的“黑盒子”模型能够输出比较理想的结果。隐式马尔可夫模型和隐式半马尔可夫模型是近来新被引入预测领域的方法。至今为止，如何采用隐式马尔可夫模型和隐式半马尔可夫模型进行预测的研究仍处于启蒙阶段。和其他“黑盒子”模型不同，马尔可夫链相关的模型有一个相对清晰的预测处理过程。文献[117]设计了一个 SVM-HMM 模型，将矢量支持向量机和隐式马尔可夫模型相结合来鉴别非稳定时间序列的发生，此类时间序列暗示设备正处于

异常状态或者正在偏离正常运作状态。在未来的研究中，对此类隐式或隐式半式马尔可夫组合模型值得进行更多的研究，并设计出理想的设备健康状态预测模型。

（3）许多“新”理论和方法被引入，用于设备健康的预测问题。这些理论和方法大多曾在别的领域得到过成功运用，如灰色模型、马尔可夫链等。这些“新”理论方法在数据处理和分析方面有它们特有的优势，有效减少了计算复杂度，增加了预测精确度。

目前，在 CBM 的研究领域中，预测仍旧是一个相对较新的研究课题。在已有文献的预测模型中，存在如下的一些不足。

（1）大多数研究都限制在某个特定领域内，缺少通用性。已有的设备健康状态的预测方法/算法大多具有其特定的应用领域。

（2）搜集大量充足的数据不仅困难，而且成本高昂。许多模型的数据训练和算法都要求在拥有大量历史数据的基础上进行，而这些数据不仅包括了传感器在设备普通状态下捕捉到的数据，还需要故障状态下的数据，甚至破坏系统/组件而得到的损毁数据，要得到这些数据不仅代价高昂，而且需要相当长的数据搜集时间。

（3）目前大部分各类所谓的“实时”维护系统，只是将传感器搜集到的数据用作诊断和预测模型的实时输入数据，模型本身通常不具有采用在线的实时数据进行更新的能力。这些静态的训练数据会降低模型预测和诊断结果的精确度。可以考虑将一些能够完成快速运算的方法纳入模型的设计中，以达到在线更新模型的目的。

（4）缺少对预测的准确性和精确度进行评判的标准，缺少统一的考核标准来评价和比较各种预测方法。

（5）已有的大部分研究仍停留在理论阶段，很少有文献已成功应用于实际应用中。

在已有预测模型中，以上普遍存在的弱点导致了模型的长学习周期、长执行时间的问题，因此在实际应用中价值不大。大致来说，未来用于 CBM 系统中的预测技术存在以下可能的研究方向：①针对系统退化预测和有效剩余寿命的不确定性，建立有效完全的评估体系和管理方法；②为了提高预测精度，可以在决策系统中建立预测结果的处理方法与择优规则。例如，当模型计算出有效剩余寿命估值的概率时，最好能同时给出预测值与真实剩余寿命值间的误差范围，而且可以对预测值进行处理和选择，使其能更有效地应用于维护决策的制定中。同时，这些新引入的

预测理论和方法需要更多地应用到实际中，来证明它们的有效性。相较那些具有领域特殊性的模型而言，应鼓励更多通用性强的系统性模型被改造引用到快速发展变化的工业界中来。

另一个研究趋势是如何将预测技术用于设备维护策略的制定中。对设备失效时间的准确预测可以帮助建立更高效的设备更换和备件库存管理制度。图 2-8 描述了一个系统性的设备维护框架，在实时诊断与预测信息的基础上，可以更加高效率、低成本地进行维护运作。

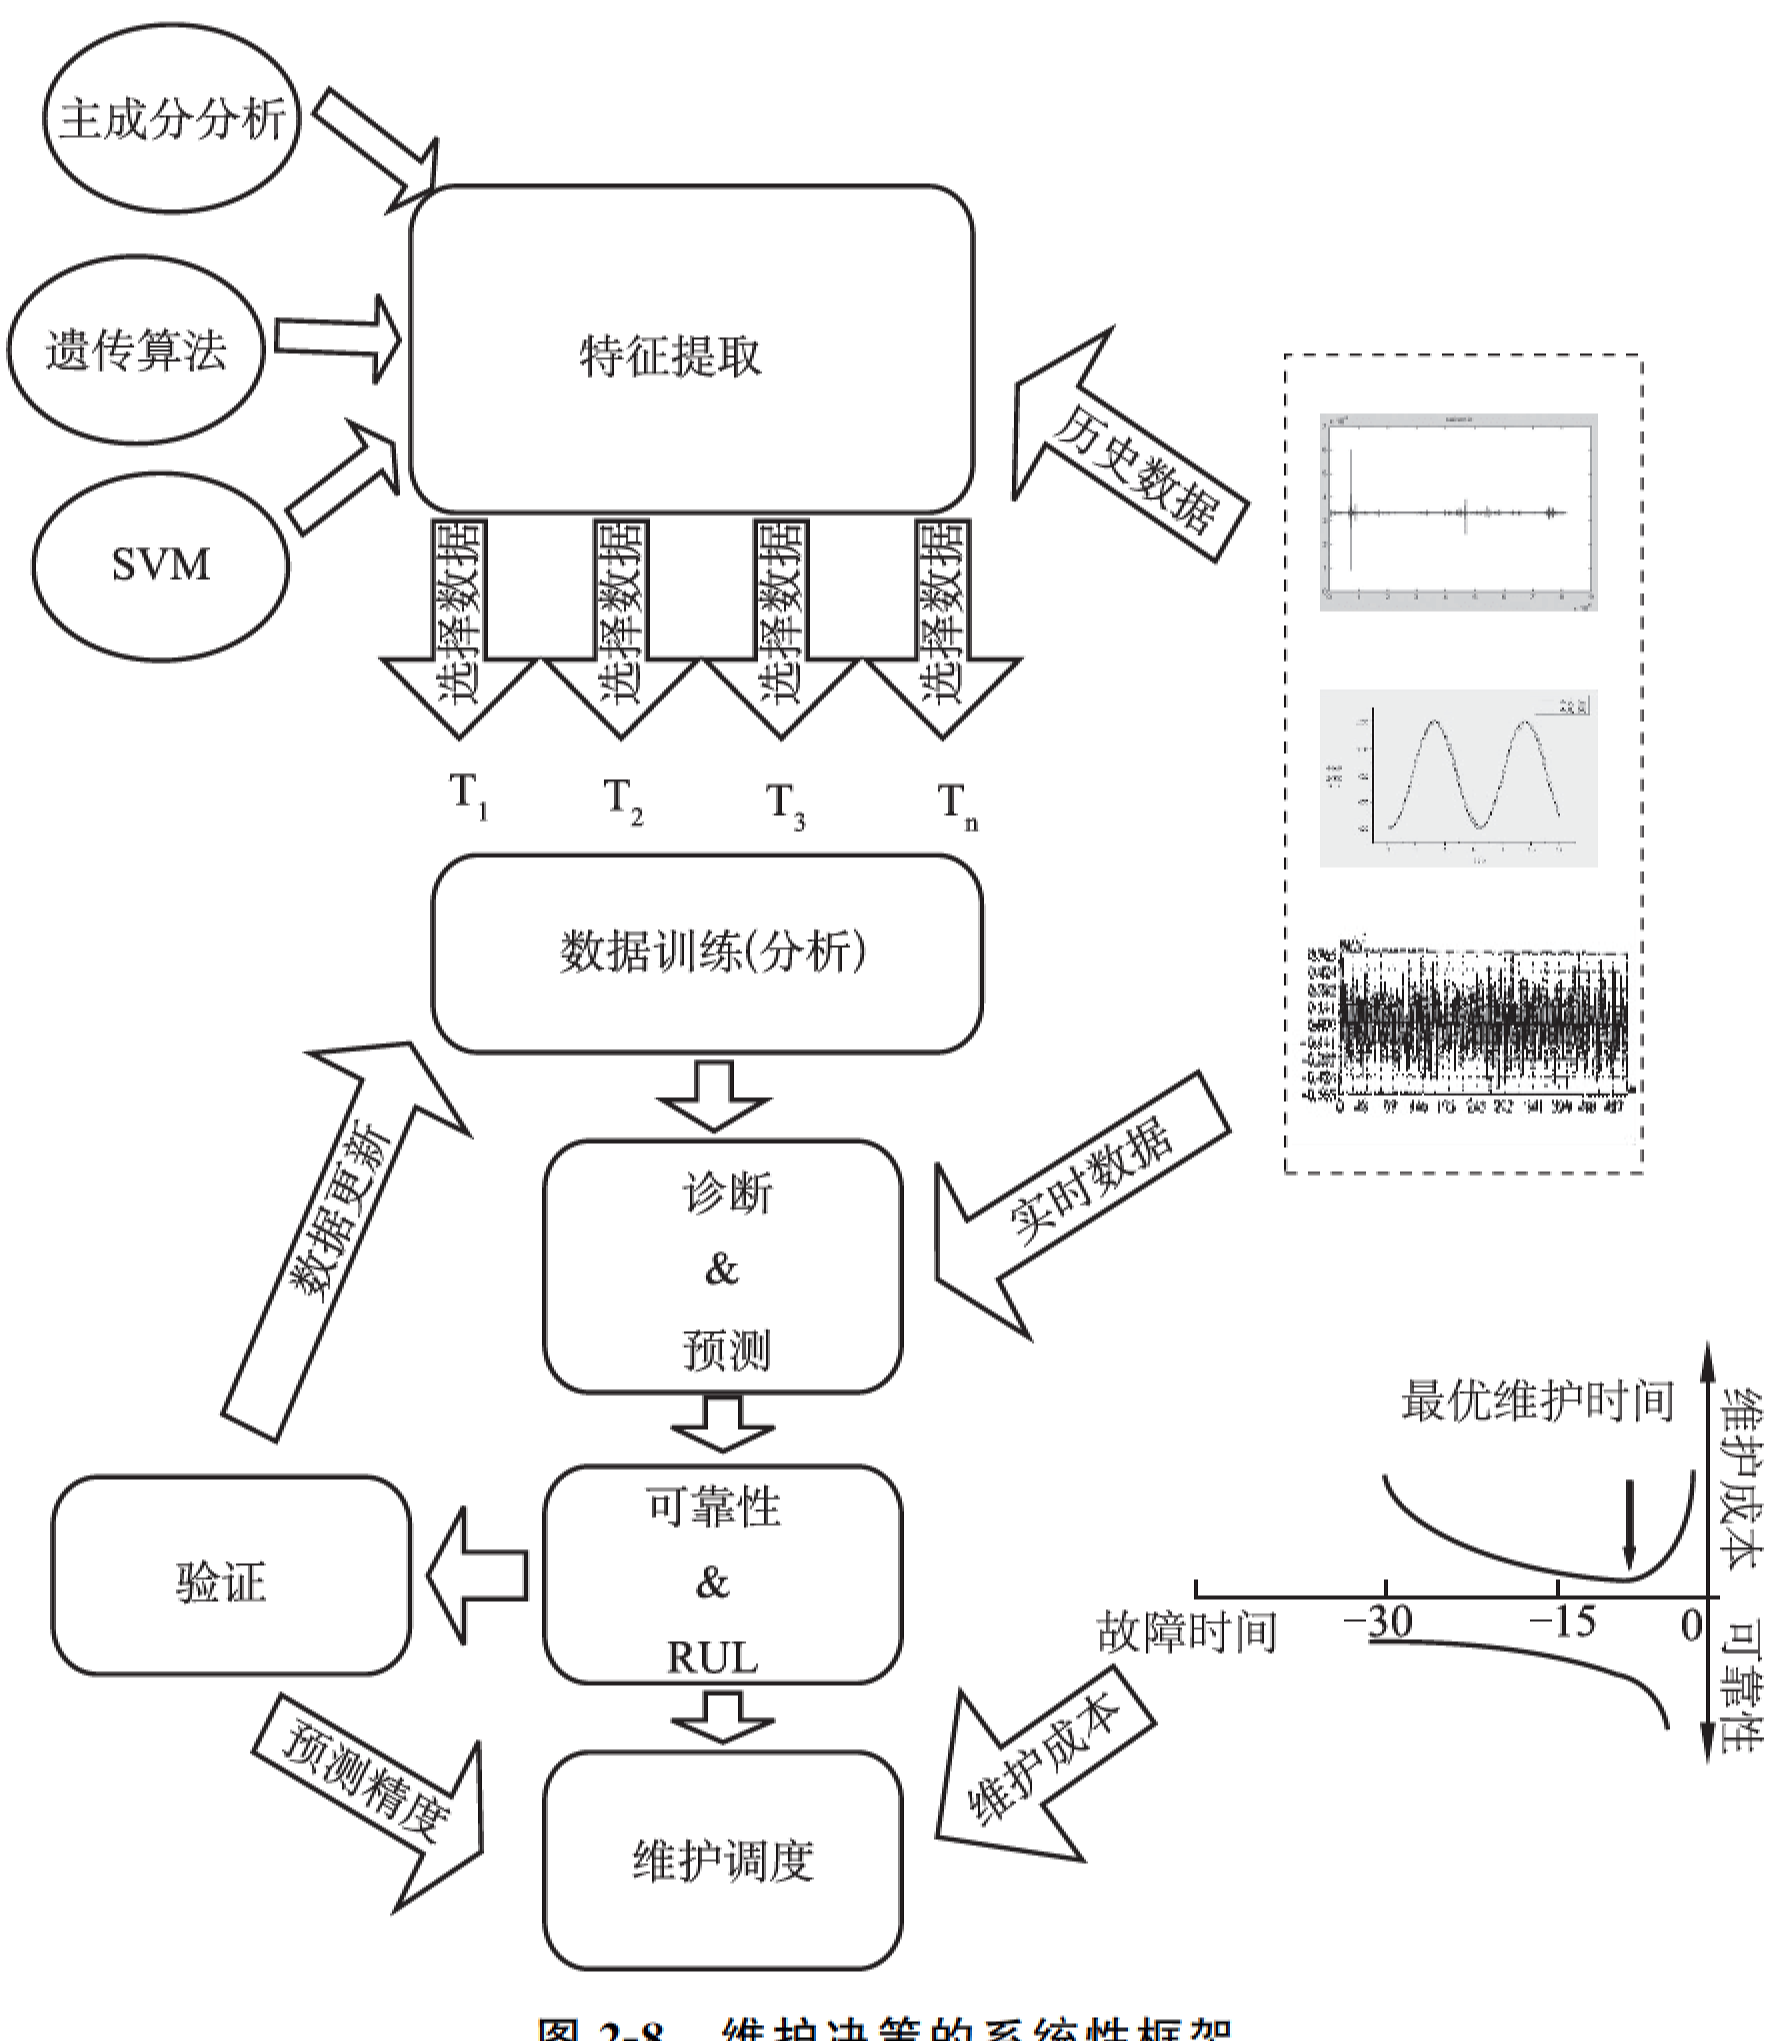


图 2-8　维护决策的系统性框架



第 3 章 单监测信息的在线健康预测

3.1 引　　言

设备在生产运转过程中，随着时间的增加，会出现设备健康状态的衰退。因此，基于设备的衰退信息，识别设备的健康状态变化趋势及计算剩余有效寿命，有助于设备采取合理的维护措施。在设备的健康状态恶化前，对设备进行维护修理，可以避免设备大的维护，降低设备的故障率和设备的维护成本，提高设备的利用率和企业的生产效率。为了建立更好的设备维护模型，本章介绍设备的单监测信息的在线健康预测模型，以及剩余寿命与健康状态之间的关系。

基于健康预测的设备维护决策，主要包括数据采集、数据处理和维护策略优化。维护策略的优化涉及设备的诊断及其预测两方面的内容。设备的健康预测更好地描述了设备的健康状态与趋势，从而影响设备的有效维护策略的建模。

当前，设备的健康预测方法主要有四类：基于物理模型的方法、基于数据驱动的方法、基于模型驱动的方法和基于信息融合的方法。基于物理模型的方法很难描述一个设备衰退的趋势与详细的建模过程，并且，需要对设备进行停机处理，在设备的生产运转过程中，这是不允许的。基于数据驱动的设备健康预测方法，这类

方法具有两个比较大的缺陷:非常慢的收敛性及容易陷入局部最优解。由于数据驱动的原因,这些模型具有很高的计算复杂性,容易造成计算爆炸问题,这些缺陷限制了这些方法的应用和发展。基于模型驱动的设备健康预测方法,这类方法的识别和训练过程需要耗费较长的时间,不适合设备在线的健康预测,因此,这类模型常用于离线健康预测。针对这类方法的离线特性,本章建立了设备单监测信息的在线健康预测模型。

在本章建模中,HMM 是一个双重的随机过程模型,而且,对于设备各个健康状态,它们之间的演化也具有随机性,设备状态中观测到的数据信息是随机的。这就说明了,对于 HMM 的真实状态,是不能被直接观测的,是隐藏的,通过数据的有效处理与分析来推测设备的真实状态。设备在使用过程中的状态识别与检测,是不能发现设备的真实状态的,可以利用来自传感器的监测信息进行推断设备的健康状态。对于 HMM 在设备中的状态监测、识别与预测,存在一些研究,并获得了不错的效果[215,216]。

由于 HMM 的状态驻留时间是遵循指数分布的,因而模型中的时间结构不能被详细准确地描述,这是 HMM 的一个内在局限性。对于这个问题,在文献[217]中,连续的 HMM 被应用于语音识别领域。并且,改进后的 HMM 模型对于语音识别的误差率降低了一半。从而证明了,系统的识别性能也可以得到极大提高[218,219]。在设备的诊断领域,文献[220]将 HMM 方法引入设备的健康预测和诊断中。将设备所经历的所有健康状态分别建立并训练对应的 HMM。假设训练好的所有 HMM 之间的状态转移时间遵循特定的多变量分布,可用向量进行估值。当确定状态的分布函数后,如果给定设备的前一个健康状态,也可以随之获得设备转移到另一个健康状态的条件概率分布。之前,有一部分学者把 HMM 引入诊断预测领域中[221-227]。在这些应用中,仍然受 HMM 固有局限性的约束。让 HMM 无法对设备真实的情况做出具有高准确度的建模,从而造成了其预测和诊断结果的可靠度是不高的。因此,为了克服因马尔可夫链的假设所造成的 HMM 的局限性,在 HMM 的结构上加入了时间部分,衍生出了 HSMM 方法。

本章针对 HSMM 的特点,构建单监测信息的在线健康预测方法,在线获得设备的每个健康状态的演化规律。设备的每个健康状态对应 HSMM 中的一个片段。通过训练好的在线算法对设备的故障进行分类和对设备的剩余寿命进行预测。在线 HSMM 经过训练后,还可以估计每个健康状态的驻留时间。一个基于在线 HSMM 宏观状态的预测方法可以使用持续时间的估值来预测设备的有

效剩余寿命。与已有的文献相比，本章节提出了单监测信息的设备在线健康预测框架。

3.2 设备在线健康预测方法

对于设备的健康预测，将健康状态之间的转移关系和每个健康状态的驻留信息作为健康预测模型的输入，预测设备的健康状态发展趋势和计算设备的剩余寿命有效值。通过健康预测算法可以获得 HSMM 的参数值，其中，根据观察值和健康状态的轨迹，可以估计每个健康状态的状态驻留值。在本节中，主要描述了设备单监测信息的在线健康预测方法。

首先，基于 HSMM 方法和 SMC 方法，提出了一个新颖的单监测信息在线健康状态识别算法。其次，将利用传感器收集的设备监测数据作为提出方法的输入值，随着不断获得的设备状态信息，发展了新的在线剩余寿命预测方法，主要目的就是应用 SMC 方法，获得联合多步向前健康状态识别算法。最后，描述了设备的在线健康预测流程。

提出的在线健康预测算法主要包含两个过程(见图 3-1)。对设备的健康预测来说，学习阶段(即离线阶段)将产生一个合适的健康预测模型，在线阶段将识别设备当前的健康状态和预测设备的剩余寿命。模型的第一个阶段主要是指模型的离线阶段，处理来自传感器的设备状态监测数据，用来训练 HSMM。模型的第二个阶段主要是模型的在线阶段，利用新方法来在线识别设备的当前健康状态，并且计算相应的设备剩余寿命。

3.2.1 数据预处理及特征提取

为了验证模型的有效性，需要对设备进行监测，经过传感器采集或人工采集的设备监测数据不一定能直接用于后续的数据分析和数据输入，如果直接用于模型分析，将会影响后续模型分析过程的有效性和应用性。因而，在验证模型的有效性时，对监测的设备原始数据进行预处理，就显得十分重要。根据小波变换的方法，对原始监测数据进行有效的预处理，将预处理后的数据作为模型的输入，进行模型

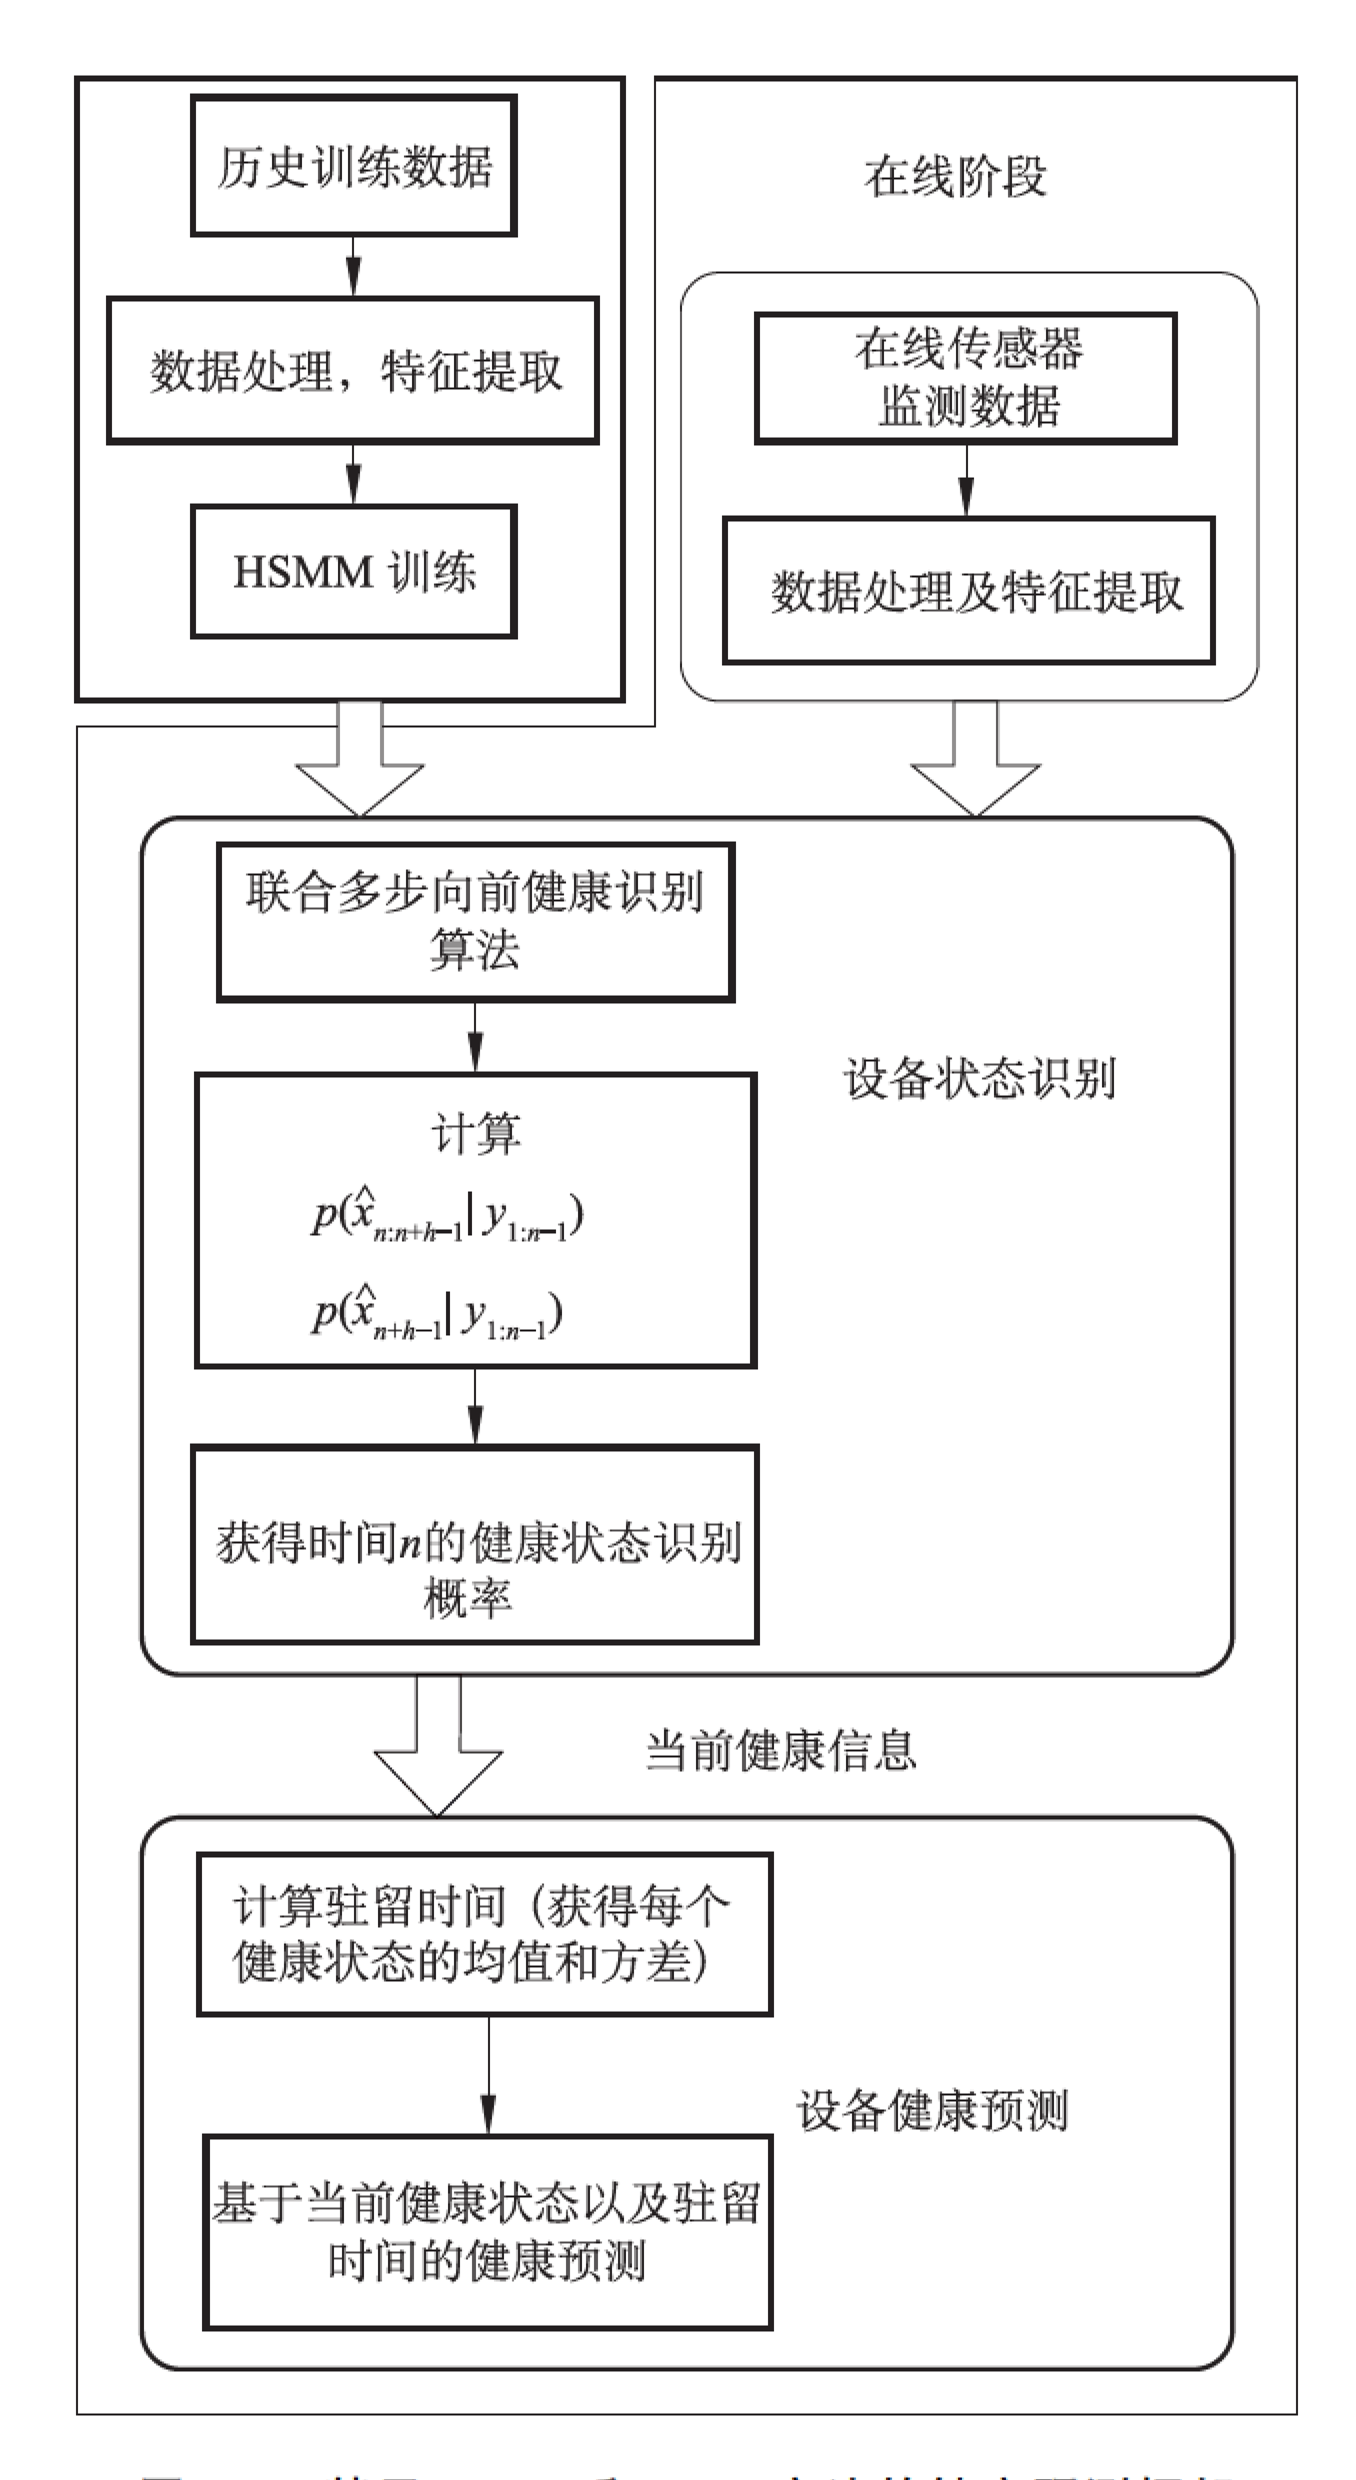


图 3-1　基于 HSMM 和 SMC 方法的健康预测框架

分析，验证模型的实用性和有效性。

数据预处理算法包括特征提取和矢量量化。首先描述检测数据的特征提取。由于系统的每部分结构是不同的，所以当一个系统发生故障时，经常会产生大量的非稳态信号。在每一个频带，输出信号的性能是不同的，小波分析方法可以自动地把不同频率信号分解成不同的频带，这样可以增加时间—频率分辨率，并实现设备

故障特征提取。利用小波变换的故障特征提取算法描述如下。

（1）监测的振动信号被分解为 V-层的小波信号，分别提取从 V-层信号的低频到高频的 2^V 个频带的小波系数（$X_j(j=1,2,\cdots,2^V)$）。

（2）重建小波包系数和提取每个频带的信号 $S_j(j=1,2,\cdots,2^V)$。

（3）计算每个频带信号的总能量，计算公式如下：

$$E_j = \int |S_j(t)|^2 \mathrm{d}t = \sum_{k=1}^{n} |x_{jk}|^2$$

其中，$x_{jk}(j=1,2,\cdots,2^V,k=1,2,\cdots,n)$，重建信号离散点的振幅。

（4）根据下列方程，建立和标准化特征向量

$$E = (\sum_{j=1}^{2^V} |E_j|^2)^{1/2}$$

因此，特征向量 $\boldsymbol{F}$ 等于 $\boldsymbol{F}'$（即，$\boldsymbol{F}'=(E_1,E_2,\cdots,E_{2^V})/E$）。

当小波故障特征向量作为 HSMM 的输入值时，特征向量必须标准化。自组织特征映射（Self-organization map，SOM）常用于进行向量的矢量量化，SOM 主要模拟了大脑神经系统的自组织特征映射的功能，它是一个有竞争力的学习网络与无监督和自组织学习过程。

3.2.2　在线健康预测算法

本章的主要目的是为连续时间函数的单监测信息的实时健康状态识别和剩余寿命预测提供合适的算法。因此，基于 SMC 方法，一种新颖的识别算法被应用于解决 HSMM 的识别问题。目前，对于 HSMM，主要关注的内容有两个方面：①通过估计概率分布 $p(x_n|y_{1:n-1})$ 的一步向前状态识别算法；②通过估计概率分布 $p(x_{n+h}|y_{1:n-1})$ 的多步向前健康状态识别方法。然而，由于忽略了 HSMM 的一致性原则，$p(x_n|y_{1:n-1})$ 和 $p(x_{n+h}|y_{1:n-1})$ 的健康状态识别路径不是非常准确。在健康状态识别中，连续性原则是非常重要的。并且，对于在线健康状态识别，连续性原则也是必须遵循的和非常重要的。因此，基于联合概率分布 $p(x_{n:n+h}|y_{1:n-1})$，提出了一种新颖的联合多步向前健康状态识别算法，遵循连续性的识别路径，该方法提供了最准确的健康状态的识别。本章中，为了说明提出方法的先进性、可用性和准确性，联合多步向前健康状态识别算法与一般的多步向前健康状态识别算法和一步向前健康状态识别算法进行比较，并在案例中进行详细的分析。

给定设备从初始时间到时间 $n-1$ 的全部可用状态监测信息，通过联合 HSMM 和 SMC 方法，提出了一种新颖的联合多步向前健康状态识别算法。并且，将提出的算法应用到在线设备隐藏故障识别中，因为在该算法中，对于设备的健康状态识别，HSMM 具有丰富的数据结构。联合多步向前健康状态识别算法可以准确地描述设备隐藏状态和监测信息之间的关系。

健康状态识别算法与一步向前健康状态识别是相互关联的。基于提出的算法①，一步向前健康状态识别的状态概率密度函数可以通过一种递归的方式来获得。假设状态概率密度函数 $p(x_{n-1} \mid y_{1:n-1})$ 可以用 $\{x_{0:n-1}^{(i)}, w_{n-1}^{i}\}_{i=1}^{N_s}$ 来近似表示，因此，状态概率密度函数可表达为

$$p(x_{n-1} \mid y_{1:n-1}) = \sum_{i=1}^{N_s} w_{n-1}^{i} \delta(x_{n-1} - x_{n-1}^{i})$$

状态概率密度函数 $p(\hat{x}_n \mid y_{1:n-1})$ 可以用来自 $\{x_{0:n-1}^{i}, w_{n-1}^{i}\}_{i=1}^{N_s}$ 的新的观测样本来表示(符号^代表预测值)。因此，一步向前健康状态识别算法的流程可以被描述为：

算法①. 在线一步向前健康状态识别算法

步骤 1. 对于预测值 $\hat{x}_n^i \sim p(\hat{x}_n \mid x_{n-1}^{i})$，预测的一步向前概率密度函数可以表示为

$$p(\hat{x}_n \mid y_{1:n-1}) \approx \sum_{i=1}^{N_s} w_{n-1}^{i} \delta(\hat{x}_n - \hat{x}_n^{i})$$

步骤 2. 更新权重 $\hat{w}_n^i = p(y_n \mid \hat{x}_n^i) w_{n-1}^{i}$，可以获得

$$w_n^i = \hat{w}_n^i / \sum_{i=1}^{N_s} \hat{w}_n^i$$

步骤 3. 根据下列方程计算状态概率密度

$$p(\hat{x}_n \mid y_{1:n}) \approx \sum_{i=1}^{N_s} w_n^i \delta(\hat{x}_n - \hat{x}_n^i)$$

为了有效地预测设备健康状态，在算法①的基础上，提出了联合多步向前健康状态识别算法。并且，基于当前的健康状态识别算法①，可以获得 $p(x_{n-1} \mid y_{1:n-1})$。根据条件概率和概率的链条规则，可以获得联合多步向前概率函数表达式：

$$p(\hat{x}_{n:n+h-1} \mid y_{1:n-1}) = \prod_{j=0}^{h-1} p(\hat{x}_{n+j} \mid y_{1:n-1}, \hat{x}_{n:n+j-1})$$

在上面的联合概率方程中，$p(\hat{x}_{n+j} \mid y_{1:n-1}, \hat{x}_{n:n+j-1})$，$j=0,1,\cdots,h-1$ 仅仅是多步

向前健康状态识别概率，并且可以用 $\{\hat{x}^i_{n+h}x^i_{0:n-1}, w^i_{n+h-1}\}_{i=1}^{N_s}$ 来近似表达，因此

$$
\begin{aligned}
p(x_{n+h} \mid y_{1:n}) &= \int\cdots\int \prod_{j=n+1}^{n+h} p(x_j \mid x_{j-1}) p(x_n \mid y_{1:n}) \prod_{j=n}^{n+h-1} \mathrm{d}x_j \\
&\approx \sum_{i=1}^{N_s} w^i_n \int\cdots\int \prod_{j=n+2}^{n+h} p(x_j \mid x_{j-1}) p(x_{n+1} \mid x^i_n) \mathrm{d}x_{n+1:n+h-1} \\
&\approx \sum_{i=1}^{N_s} w^i_{n+h} \delta(\hat{x}_{n+h} - \hat{x}^i_{n+h})
\end{aligned}
$$

其中，$\delta(.)$是狄拉克函数[233]。

基于上述内容，设备联合 h 步向前健康状态识别概率可以用一些粒子来近似表达，为了更准确地表示联合 h 步向前健康状态识别概率，这些粒子都具有相应的权重，这些权重可以表示为

$$
\{(\hat{x}^{i_0}_n, \cdots, \hat{x}^{i_{h-1}}_{n+h-1}), (\hat{w}^{i_0}_{n-1}, \cdots, \hat{w}^{i_{h-1}}_{n+h-2})\}^{N_s}_{i_0,\cdots,i_{h-1}=1}
$$

因此，联合 h 步向前健康状态识别概率可以表示为

$$
\begin{aligned}
p(\hat{x}_{n:n+h-1} \mid y_{1:n-1}) = \sum_{i_0=1}^{N_s}\cdots\sum_{i_{h-1}=1}^{N_s} (\hat{w}^{i_0}_{n-1}, \cdots, \hat{w}^{i_{h-1}}_{n+h-2}) \\
\delta(\hat{x}_n - \hat{x}^{i_0}_n, \cdots, \hat{x}_{n+h-1} - \hat{x}^{i_{h-1}}_{n+h-1})
\end{aligned}
\tag{3-1}
$$

通过下述的算法②来描述在线联合多步向前健康状态识别算法。

算法②　在线联合多步向前(h 步)健康状态识别算法

步骤 1　基于算法①中的步骤 1，一步向前状态概率密度函数可以表示为

$$
p(\hat{x}_n \mid y_{1:n-1}) \approx \sum_{i=1}^{N_s} w^i_{n-1} \delta(\hat{x}_n - \hat{x}^i_n)
$$

步骤 2　如果 $h=1$，算法流程直接跳转到步骤 3，否则，设置 $k=1$。

步骤 2.1　在这一步中，预测值 $\{\hat{x}^i_{n+k-1}\}_{i=1}^{N_s}$ 来更新权重 $\{w^i_{n+k-2}\}_{i=1}^{N_s}$，基于方程 $w^i_{n+k-1} = p(\hat{y}^i_{n+k-1} \mid \hat{x}^i_{n+k-1}) w^i_{n+k-2}$，预测的多步向前条件概率密度函数可以表示为

$$
p(\hat{x}_{n+k-1} \mid y_{1:n-1}, \hat{x}_{n:n+k-2}) \approx \sum_{i=1}^{N_s} w^i_{n+k-1} \delta(\hat{x}_{n+k-1} - \hat{x}^i_{n+k-1})
$$

步骤 2.2　对于预测值 $\hat{x}^i_{n+k} \sim p(\hat{x}_{n+k} \mid \hat{x}^i_{n+k-1})$，预测的多步向前概率密度函数可以表示为

$$
p(\hat{x}_{n+k} \mid y_{1:n-1}) \approx \sum_{i=1}^{N_s} w^i_{n+k-1} \delta(\hat{x}_{n+k} - \hat{x}^i_{n+k})
$$

步骤 2.3　更新 $k=k+1$。如果 $k=h$，基于式(3-1)，可以获得联合 h 步向前健

康状态识别概率密度函数，因此跳转到步骤 3，否则，返回步骤 2.1。

步骤 3　当在线观测值 y_n 可用的时候，需要进行权重更新工作，更新表达式为 $\hat{w}_n^i = p(y_n \mid \hat{x}_n^i) w_{n-1}^i$，更新当前概率密度函数可以表示为

$$p(\hat{x}_n \mid y_{1:n}) \approx \sum_{i=1}^{N_s} w_n^i \delta(\hat{x}_n - \hat{x}_n^i)$$

基于算法②，对于一个给定的新的连续观测数据序列，可以获得当前时刻的状态识别概率。基于获得的状态识别概率，可以有效地预测处于当前时刻的设备剩余寿命值。

显然，联合多步向前健康状态识别算法和多步向前健康状态识别算法之间的关系可以被描述为

$$p(\hat{x}_{n+h-1} \mid y_{1:n-1}) = \sum_{\hat{x}_n} \cdots \sum_{\hat{x}_{n+h-1}} p(\hat{x}_{n:n+h-1} \mid y_{1:n-1})$$

在上述的方程中，多步向前概率密度函数 $p(\hat{x}_{n+h-1} \mid y_{1:n-1})$ 是联合多步向前概率密度函数 $p(\hat{x}_{n:n+h-1} \mid y_{1:n-1})$ 的边缘分布。如果在设备健康预测中，对于预测的精度要求不是很高，那么在这种情况下，多步向前健康状态识别算法完全可以满足使用要求。如果对于健康预测精度要求比较高，则多步向前健康状态识别算法不能满足使用要求，那么在这种情况下，联合多步向前健康状态识别算法被应用到设备健康预测中。联合多步向前健康状态识别算法在实时的健康预测中具有比多步向前健康状态识别算法更高的预测精度。因为，在整个预测过程中，联合多步向前健康状态识别算法始终保持 HSMM 的马尔可夫连续性。

在获得设备的状态识别概率以后，我们还需要确定设备的健康状态转折点，设备健康状态转折点是指设备从健康状态 x_l 转移到健康状态 x_{l+1} 的时刻点。在设备健康预测的过程中，通过观察设备的健康状态转折点，从设备当前状态到健康状态转折点的时间可以被评估。在设备健康预测模型中，设备的健康状态转折点对应从健康状态 x_l 转移到健康状态 x_{l+1} 的时刻。对于如何确定设备的健康状态转移点，可以通过下列方式来进行识别：当获得新的监测信息时，应用联合多步向前在线健康状态转移算法进行状态在线识别，进行在线健康预测，如果概率密度函数 $p(S_l = x_{l+1} \mid y_{1:l-1})$ 的值在时刻 l 前一直是增加的，并且，在时刻 l，$p(S_l = x_{l+1} \mid y_{1:l-1})$ 获得最大值，则时刻 l 就是设备健康预测过程中的状态转折点。

假设设备存在两个健康状态，则对于实时观测向量 $y_1 y_2 \cdots y_T$，设备的识别状态序列情况如图 3-2 所示。从图 3-2 中可以看到，每一个健康状态的序列都存在设

备的健康状态转折点。并且，基于算法②，可以获得设备停留在当前状态的概率，在此基础上，可以对设备的剩余有效寿命进行预测。

	S_1	S_2	S_3	⋯	S_{l-1}	S_l	S_{l+1}	⋯	S_{l-1}	S_l
$S^{(2)}$	x_l	x_{l+1}	x_{l+1}	⋯	x_{l+1}	x_{l+1}	x_{l+1}	⋯	x_{l+1}	x_{l+1}
$S^{(3)}$	x_l	x_l	x_{l+1}	⋯	x_{l+1}	x_{l+1}	x_{l+1}	⋯	x_{l+1}	x_{l+1}
					⋯⋯					
$S^{(l)}$	x_l	x_l	x_l	⋯	x_l	x_{l+1}	x_{l+1}	⋯	x_{l+1}	x_{l+1}
					⋯⋯					
$S^{(L)}$	x_l	x_l	x_l	⋯	x_l	x_l	x_l	⋯	x_l	x_{l+1}

图 3-2　设备健康状态识别序列（含有两个健康状态）

3.2.3　剩余有效寿命预测方法

设备的健康状态有效预测的目的就是预测设备的故障状态的发展趋势，进而获得设备的剩余有效寿命。假设设备在进入其故障状态 $F(s_n)$ 前，设备将经历几个中间状态，可以用 $s_i(i=1,2,\cdots,n-1)$ 来表示。在健康状态 s_i，设备的期望驻留时间用 $D(s_i)$ 来表示，这就说明了当设备转移到健康状态 s_i 时，停留在健康状态 s_i 的设备剩余驻留时间和设备停留在未来故障状态前的所有中间健康状态的有效剩余驻留时间的总和构成了设备总的剩余有效寿命。计算框架如图 3-3 所示。

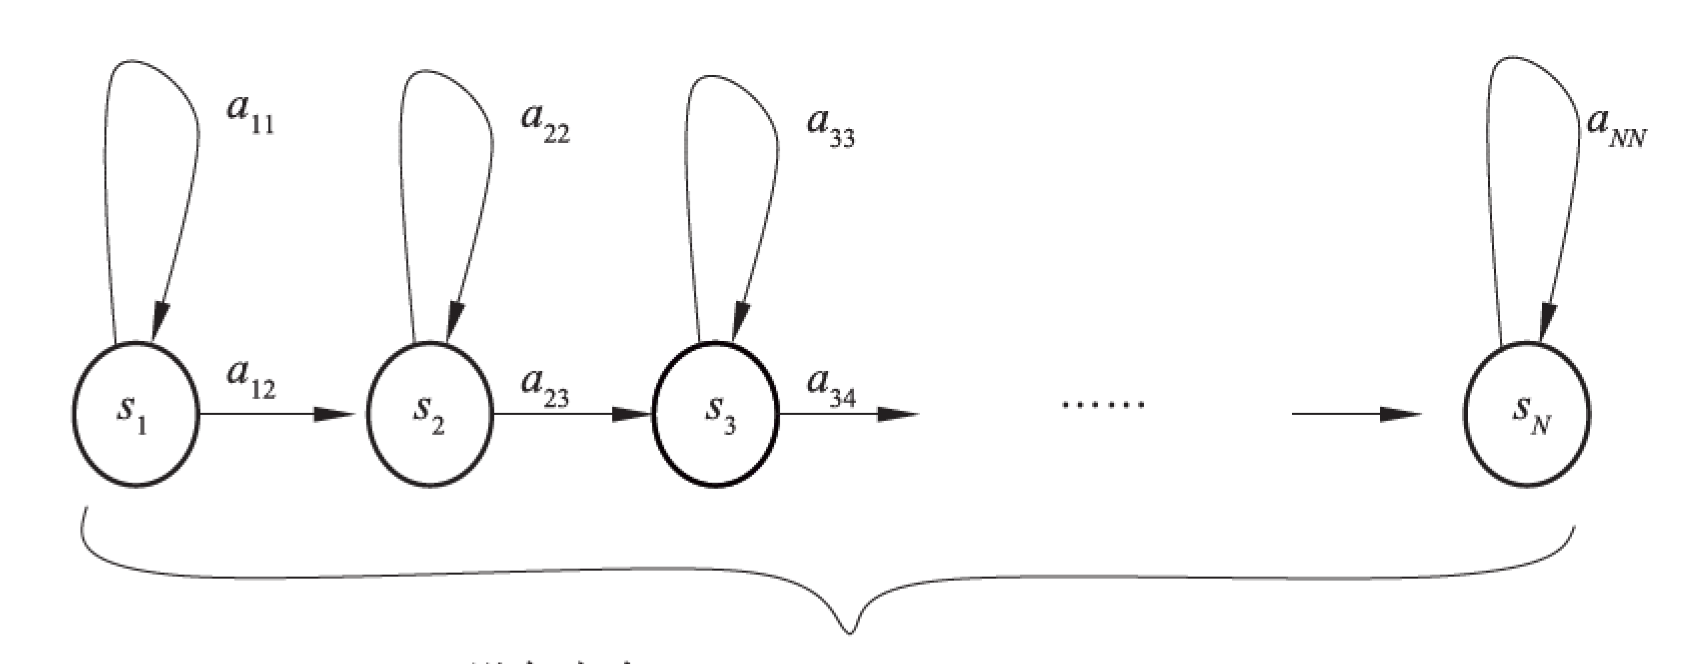


图 3-3　设备剩余寿命计算框架

在第 l 个样本观测时刻点，用 $\hat{D}(s_i^{(l)})$ 来表示设备在健康状态 s_i 的有效驻留时间，则，对于该驻留时间的计算见下列方程：

$$D(s_i)=\mu(s_i)+\rho\sigma^2(s_i)$$

$$\rho = \left[\text{lifetime} - \sum_{i=1}^{N} \mu(s_i)\right] / \sum_{i=1}^{N} \sigma^2(s_i)$$

$$\hat{D}(s_i^{(l)}) = p(S_l = s_i \mid y_{1:l}) D(s_i) \tag{3-2}$$

在上述方程中，$\mu(s_i)$ 表示健康状态 s_i 的驻留概率函数 $p_i(d)$ 的平均值；$\sigma^2(s_i)$ 表示健康状态 s_i 的驻留概率函数 $p_i(d)$ 的方差。$D(s_i)$ 是健康状态 s_i 的驻留时间，$p(S_l = s_i \mid y_{1:l})$ 表示在第 l 个样本观测时刻点，基于观察向量 $y_{1:l}$ 的健康状态 s_i 的状态概率。

当设备进入健康状态 s_i 后的第 l 个样本观测时刻点时，基于式(3-2)，设备剩余有效寿命的模型可以表示为

$$RUL^{(l)} = \hat{D}(s_i^{(l)}) + \sum_{j=i+1}^{n-1} D(s_j) \tag{3-3}$$

联合式(3-2)和式(3-3)，当设备进入状态 s_i 后的第 l 个样本观测时刻点时，可以计算求出相应的设备有效剩余寿命预测值。

本节提出的方法，将用于在线识别设备的健康状态，并且计算相应的设备剩余有效寿命。因此，在线健康预测方法的基本步骤如下。

第一步，根据以前的设备历史监测数据，对 HSMM 模型进行训练，获得最佳的适应于单监测信息在线健康预测的 HSMM 参数，包括 HSMM 的初始转移概率、设备健康状态驻留时间等。

第二步，这一步是与当前健康状态的识别有关，基于算法②，在设备进入健康状态 s_i 后的第 l 个样本观测时刻点，随着在线监测数据的获得，用联合多步向前健康状态识别算法计算健康状态 s_i 的概率密度函数值。同时，计算获得设备的健康状态转折点。

第三步，在第二步的基础上，在设备进入健康状态 s_i 后的第 l 个样本观测时刻点，按照方程式(3-2)，计算设备在健康状态 s_i 的剩余有效驻留时间。

第四步，在设备进入健康状态 s_i 后的第 l 个样本观测时刻点，按照方程式(3-3)，计算设备的剩余有效寿命。

3.3 算例分析

本章内容的实验测试，是在美国某个实验室所做的关于液压泵(设备)的长期

疲劳磨损的测试，在实验中，使用了 3 台液压泵（分别为 A，B 和 C），在实验过程中，为了促使液压泵进行磨损，在液压泵中添加了油有泥沙，在这种情况下，对于流量降低到不同程度的目的，也可以达到。针对液压泵的实验分析，在实验中的泥沙污染可以划分为四个级别：级别 1（正常状态）、级别 2（在油箱中放入 5mg，20-mm 泥沙）、级别 3（在油箱中放入 10mg，20-mm）、级别 4（在油箱中放入 15mg，20-mm）。在该磨损测试的实验过程中，对于泵的健康级别，它的流量损耗级别是直接对应于它的泥沙污染级别的，且流量损耗级别是与泥沙的污染级别正相关的。并且，在液压泵的实验中，流量是与液压泵的健康等级状态直接对应的，用来衡量液压泵的健康等级状态。所以，在实验中，液压泵的健康等级状态被液压泵流量的泥沙污染级别所定义。

在实验室的实验过程中，将液压泵加速计安装在与液压泵旋转轴平行的位置，该加速计用来进行收集在线的振动信号。图 3-4 显示了实验的组织结构。

在实验分析测试过程中，采用 Back Hoe Loader：$74cm^3/rev$ 的变量液压泵。在液压泵的监测与搜集数据的过程中，对于搜集数据数量，采样频率是 60kHz；对于来自加速计的振动信号，使用反锯齿滤波器进行处理；对于数据的特征值的提取，使用小波包中的 Daubechies wavelet 10（五层小波分解层数），从而可以对检测到的数据信号中的故障信息进行有效提取[232]；对于来自数据小波包分析操作中的小波系数，用于 HMM 方法和 HSMM 方法的输入值。在实验测试中，最先做的工作是应用 HSMM 对液压泵的健康状态进行分类，为了说明 HSMM 在设备健康预测方面的性能，对 HSMM 和 HMM 就分类性能方面进行了比较分析。

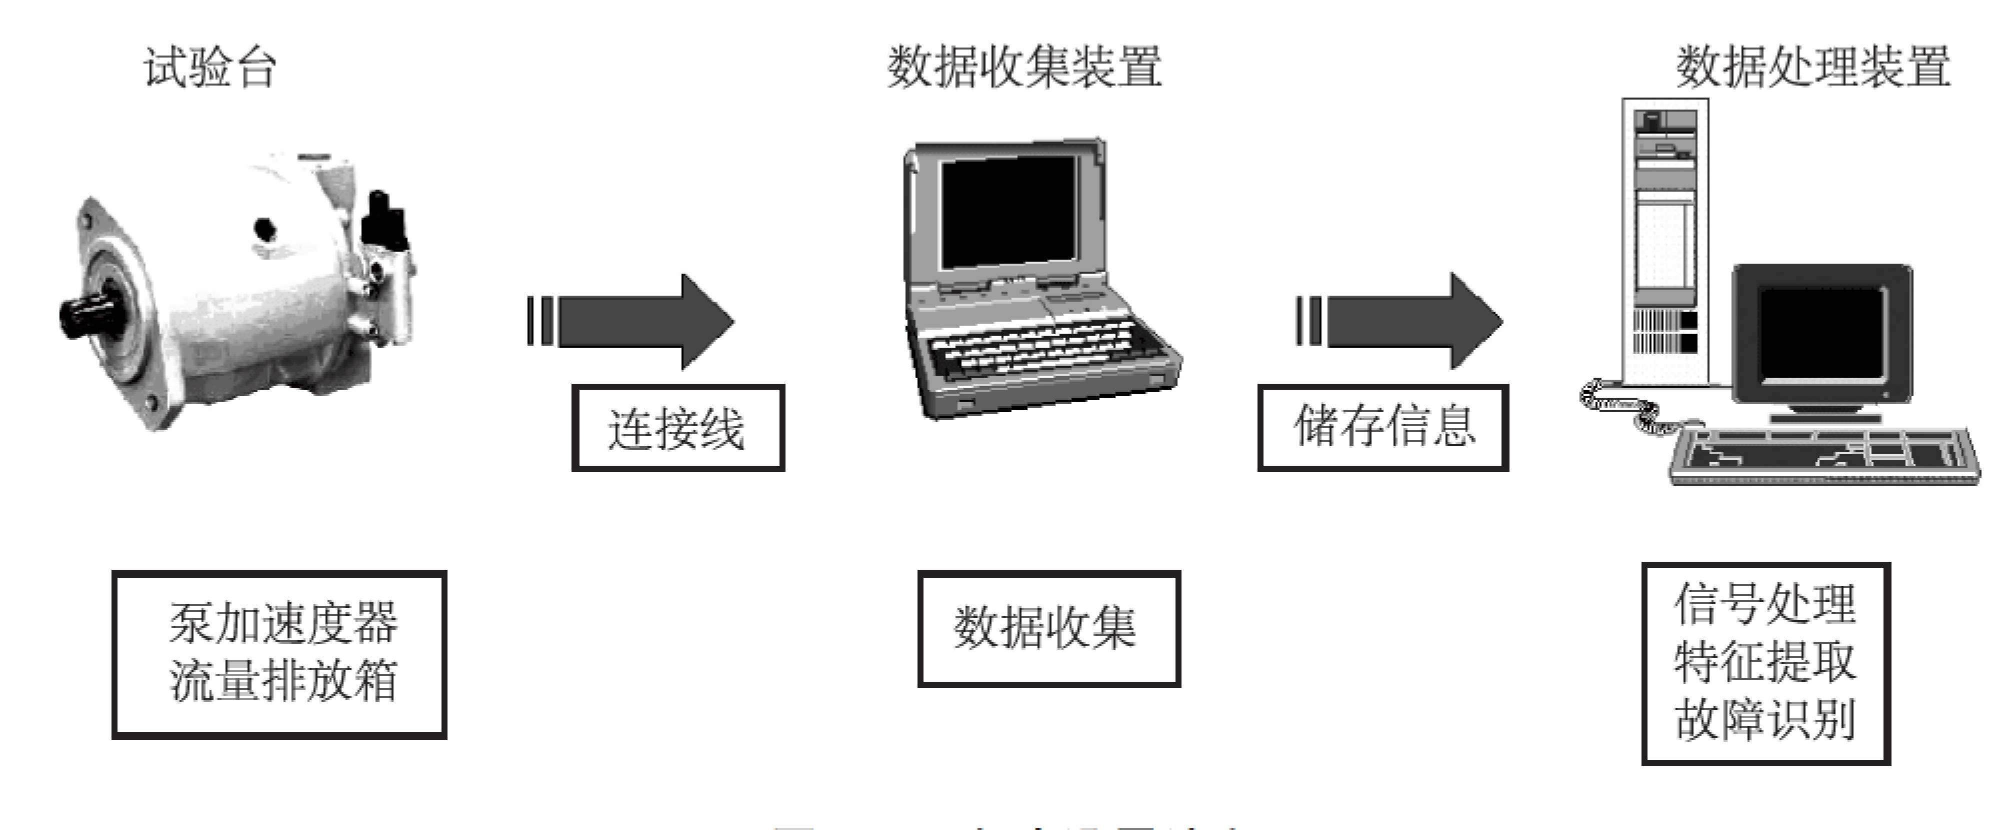


图 3-4　实验设置流程

3.3.1 基于 HSMM 的健康诊断

在实验过程中，我们首先用 HSMM 对液压泵的健康进行诊断，为了说明 HSMM 的健康诊断性能优于 HMM 的健康诊断性能，对 HSMM 和 HMM 进行了比较分析，表 3-1 描述了在每个健康状态下，关于 HSMM 和 HMM 进行训练与测试的数据标准。

表 3-1 HSMM 和 HMM 训练的数据数量（液压泵）

	健康状态 1（Baseline）		健康状态 2（Degradation 1）		健康状态 3（Degradation 2）		健康状态 4（Failure）	
	训练	测试	训练	测试	训练	测试	训练	测试
泵 A	12	2	8	1	11	2	8	2
泵 B	8	2	8	2	10	2	8	2
泵 C	8	1	8	2	8	2	9	2

表 3-2、表 3-3 和表 3-4 分别表示 HSMM 与 HMM 对三个液压泵的诊断结果。

表 3-2 泵 A 的 HSMM 和 HMM 测试结果（×表示分类错误）

最大似然值	Baseline 测试 1	Baseline 测试 2	Degradation 1 测试 1	Degradation 2 测试 1	Degradation 2 测试 2	Failure 测试 1	Failure 测试 2
HMM_B	−135.997 4	−105.592 9	—	—	—	—	—
HMM_{D1}	—	—	−16.237 5	—	—	—	—
HMM_{D2}	—	—	—	×	×	—	—
HMM_F	—	—	—	—	—	−177.537 6	×
$HSMM_B$	−0.278 7	15.405 3	—	—	—	—	—
$HSMM_{D1}$	—	—	21.924 1	—	—	—	—
$HSMM_{D2}$	—	—	−611.734 1	−25.705 7	8.879 5	−215.111 9	−204.399 9
$HSMM_F$	—	—	×	−716.202 1	−327.967 1	16.351 7	2.786 7

液压泵的健康状态识别情况如下：

对液压泵 A，基于 HMM 的分类率为 4/7＝57%。基于 HSMM 的分类率为 7/7＝100%。

对液压泵 B，基于 HMM 的分类率为 6/8＝75%。基于 HSMM 的分类率为 7/8＝87.5%。

对液压泵 C，基于 HMM 的分类率为 7/7＝100%。基于 HSMM 的分类率为 7/7＝100%。

表 3-3　液压泵 B 的 HSMM 和 HMM 测试结果（×表示分类错误）

最大似然值	Baseline 测试 1	Baseline 测试 2	Degradation 1 测试 1	Degradation 1 测试 2	Degradation 2 测试 1	Degradation 2 测试 2	Failure 测试 1	Failure 测试 2
HMM_B	35.293 2	35.592 4	—	—	—	—	—	—
HMM_{D1}	—	—	−35.980 7	−21.116 5	—	—	—	—
HMM_{D2}	—	—	—	—	9.590 3	−80.610 9	—	—
HMM_F	—	—	—	—	—	—	×	×
$HSMM_B$	29.923 2	29.874 5	—	—	—	—	—	—
$HSMM_{D1}$	—	—	11.468 4	×	−57.374 3	−89.971 9	—	—
$HSMM_{D2}$	—	—	—	—	19.037 5	18.135 7	—	—
$HSMM_F$	—	—	—	—	—	—	−73.729 1	11.69

表 3-4　泵 C 的 HSMM 和 HMM 测试结果（×表示分类错误）

最大似然值	Baseline 测试 1	Degradation 1 测试 1	Degradation 1 测试 2	Degradation 2 测试 1	Degradation 2 测试 2	Failure 测试 1	Failure 测试 2
HMM_B	33.211 1	—	—	—	—	—	—
HMM_{D1}	—	−73.323 3	−4.163 3	—	—	—	—
HMM_{D2}	—	—	—	−217.458 9	−4.714 8	—	—
HMM_F	—	—	—	—	—	29.331 3	11.283 4
$HSMM_B$	27.458 8	—	—	—	—	—	—
$HSMM_{D1}$	−584.571 0	9.981 9	16.081 0	—	−4.325 8	—	—
$HSMM_{D2}$	—	—	—	−11.433 3	21.146 4	—	—
$HSMM_F$	—	—	—	—	—	22.510 4	18.202 2

上述实验结果表明，对于设备的健康状态分类，与 HMM 相比较，HSMM 具有更高的和更精确的设备健康状态识别率，就设备总的故障诊断方面来说，HSMM 具有 96%的识别率。在实验中，对于某个液压泵的健康诊断来说，与当前 HMM 的诊断模型相比，HSMM 的正确识别率可以增加 25.3%。并且，根据实验的计算过程，对于模型的计算时间的长度，HMM 和 HSMM 基本上是相同的。所以，在实际的应用中，涉及具有大量数据集的时候，对 HMM 来说，HSMM 具有更高的识别效率。

3.3.2 数据准备与处理

原始监测数据的分析，主要包括均方根(RMS)和峰度(Kurtosis)两个方面。对设备的状态监测和运转阶段描述来说，RMS 是一个基本的特征。峰度主要描述了每一监测时刻点监测数据的频谱的趋势。一个高峭描绘了一个具有较长尾部的频谱，而低峰度描绘了一个具有较短尾部的频谱和一个集中走向均值的频谱分布。可以看出的是，在数据监测过程中，RMS 和峰度的特征显示了一个稳定的运转阶段。图 3-5 表示了监测数据的 RMS 和峰度趋势。从图 2-7 中可以看出，随着设备健康状态的不断演化和观测时刻点的增多，出现了一些具有强烈变化的时刻点。例如，第 13 个样本观测时刻点，第 23 个样本观测时刻点，第 36 个样本观测时刻点，分别出现了强烈的转折点，也就是上面所说的设备健康状态转折点。

基于上述对监测数据的 RMS 和 Kurtosis 分析，由于原始监测数据数量巨大，对于原始监测数据，在此用少数几个时刻点的监测数据来描述试验振动信号的分类信息。对应一些特殊监测时刻点，图 3-6 显示了几个原始监测数据的时域频谱。图 3-6(a)描述了第 12 个监测时刻点的信号频谱，在此时刻点，RMS=1.474，Kurtosis=0.506 75，并且液压泵处于健康状态 1(Baseline)。图 3-6(b)描述了第 13 个监测时刻点的信号频谱，在此时刻点，RMS=1.236 7，Kurtosis=0.721 27，并且液压泵从第 13 个观测时刻点开始处于健康状态 2(Degradation 1)。图 3-6(d)描述了第 23 个监测时刻点的信号频谱，在此时刻点，RMS=2.044 2，Kurtosis=6.180 3，并且液压泵从第 23 个观测时刻点开始处于健康状态 3(Degradation 2)。图 3-6(f)描述了第 37 个监测时刻点的信号频谱，在此时刻点，RMS=2.038 2，Kurtosis=6.291 7，并且液压泵从第 37 个观测时刻点开始处于健康状态 4(Failure)。

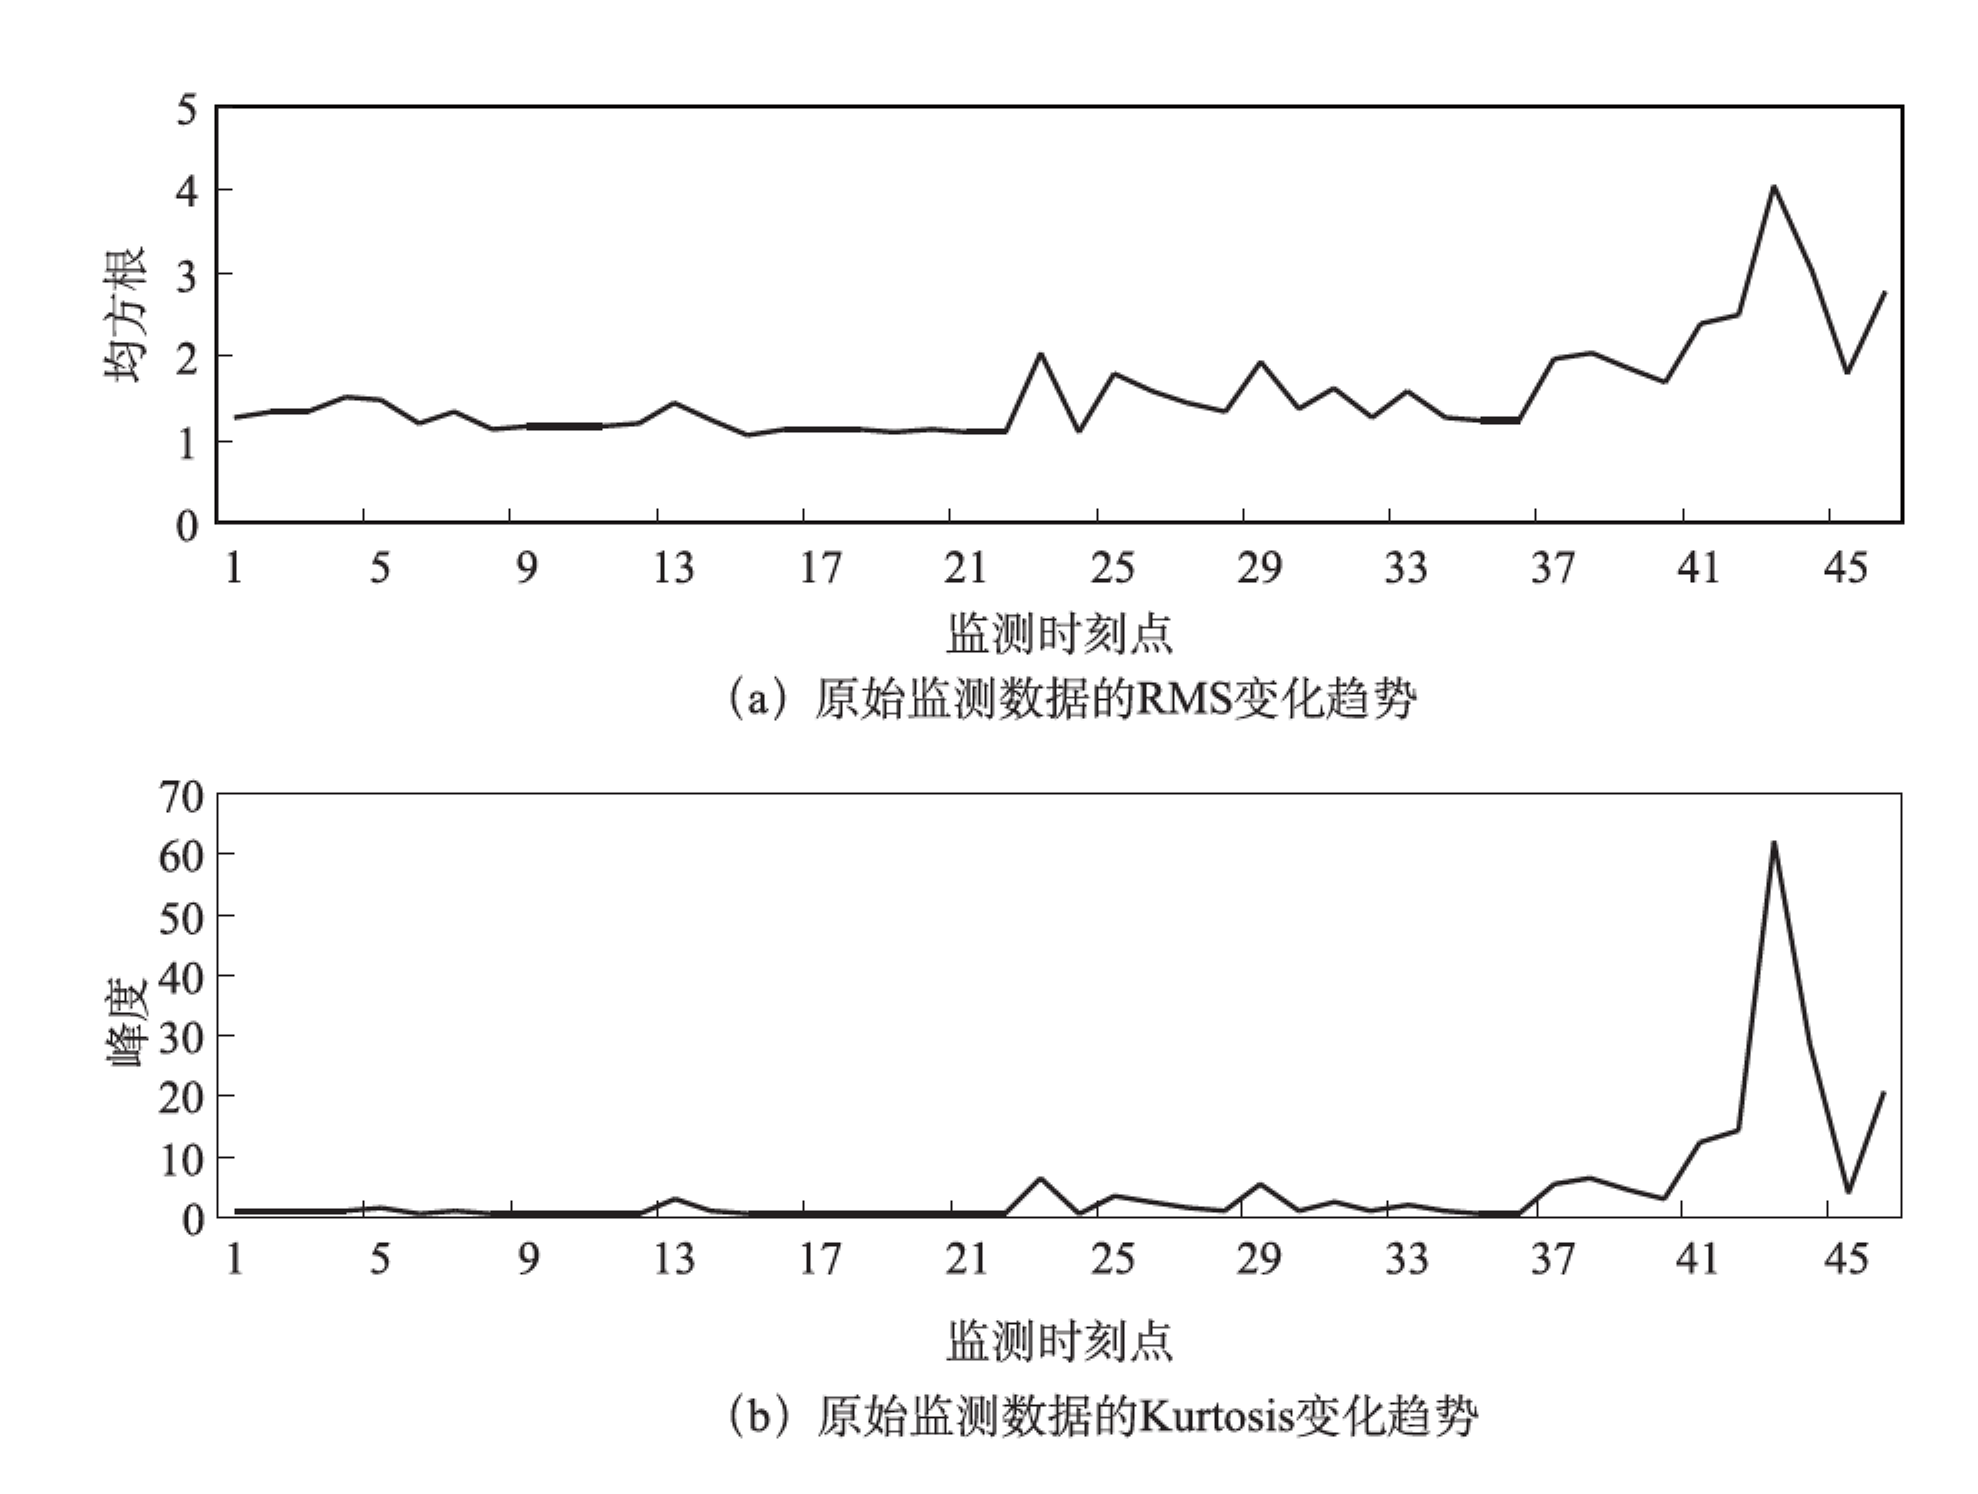
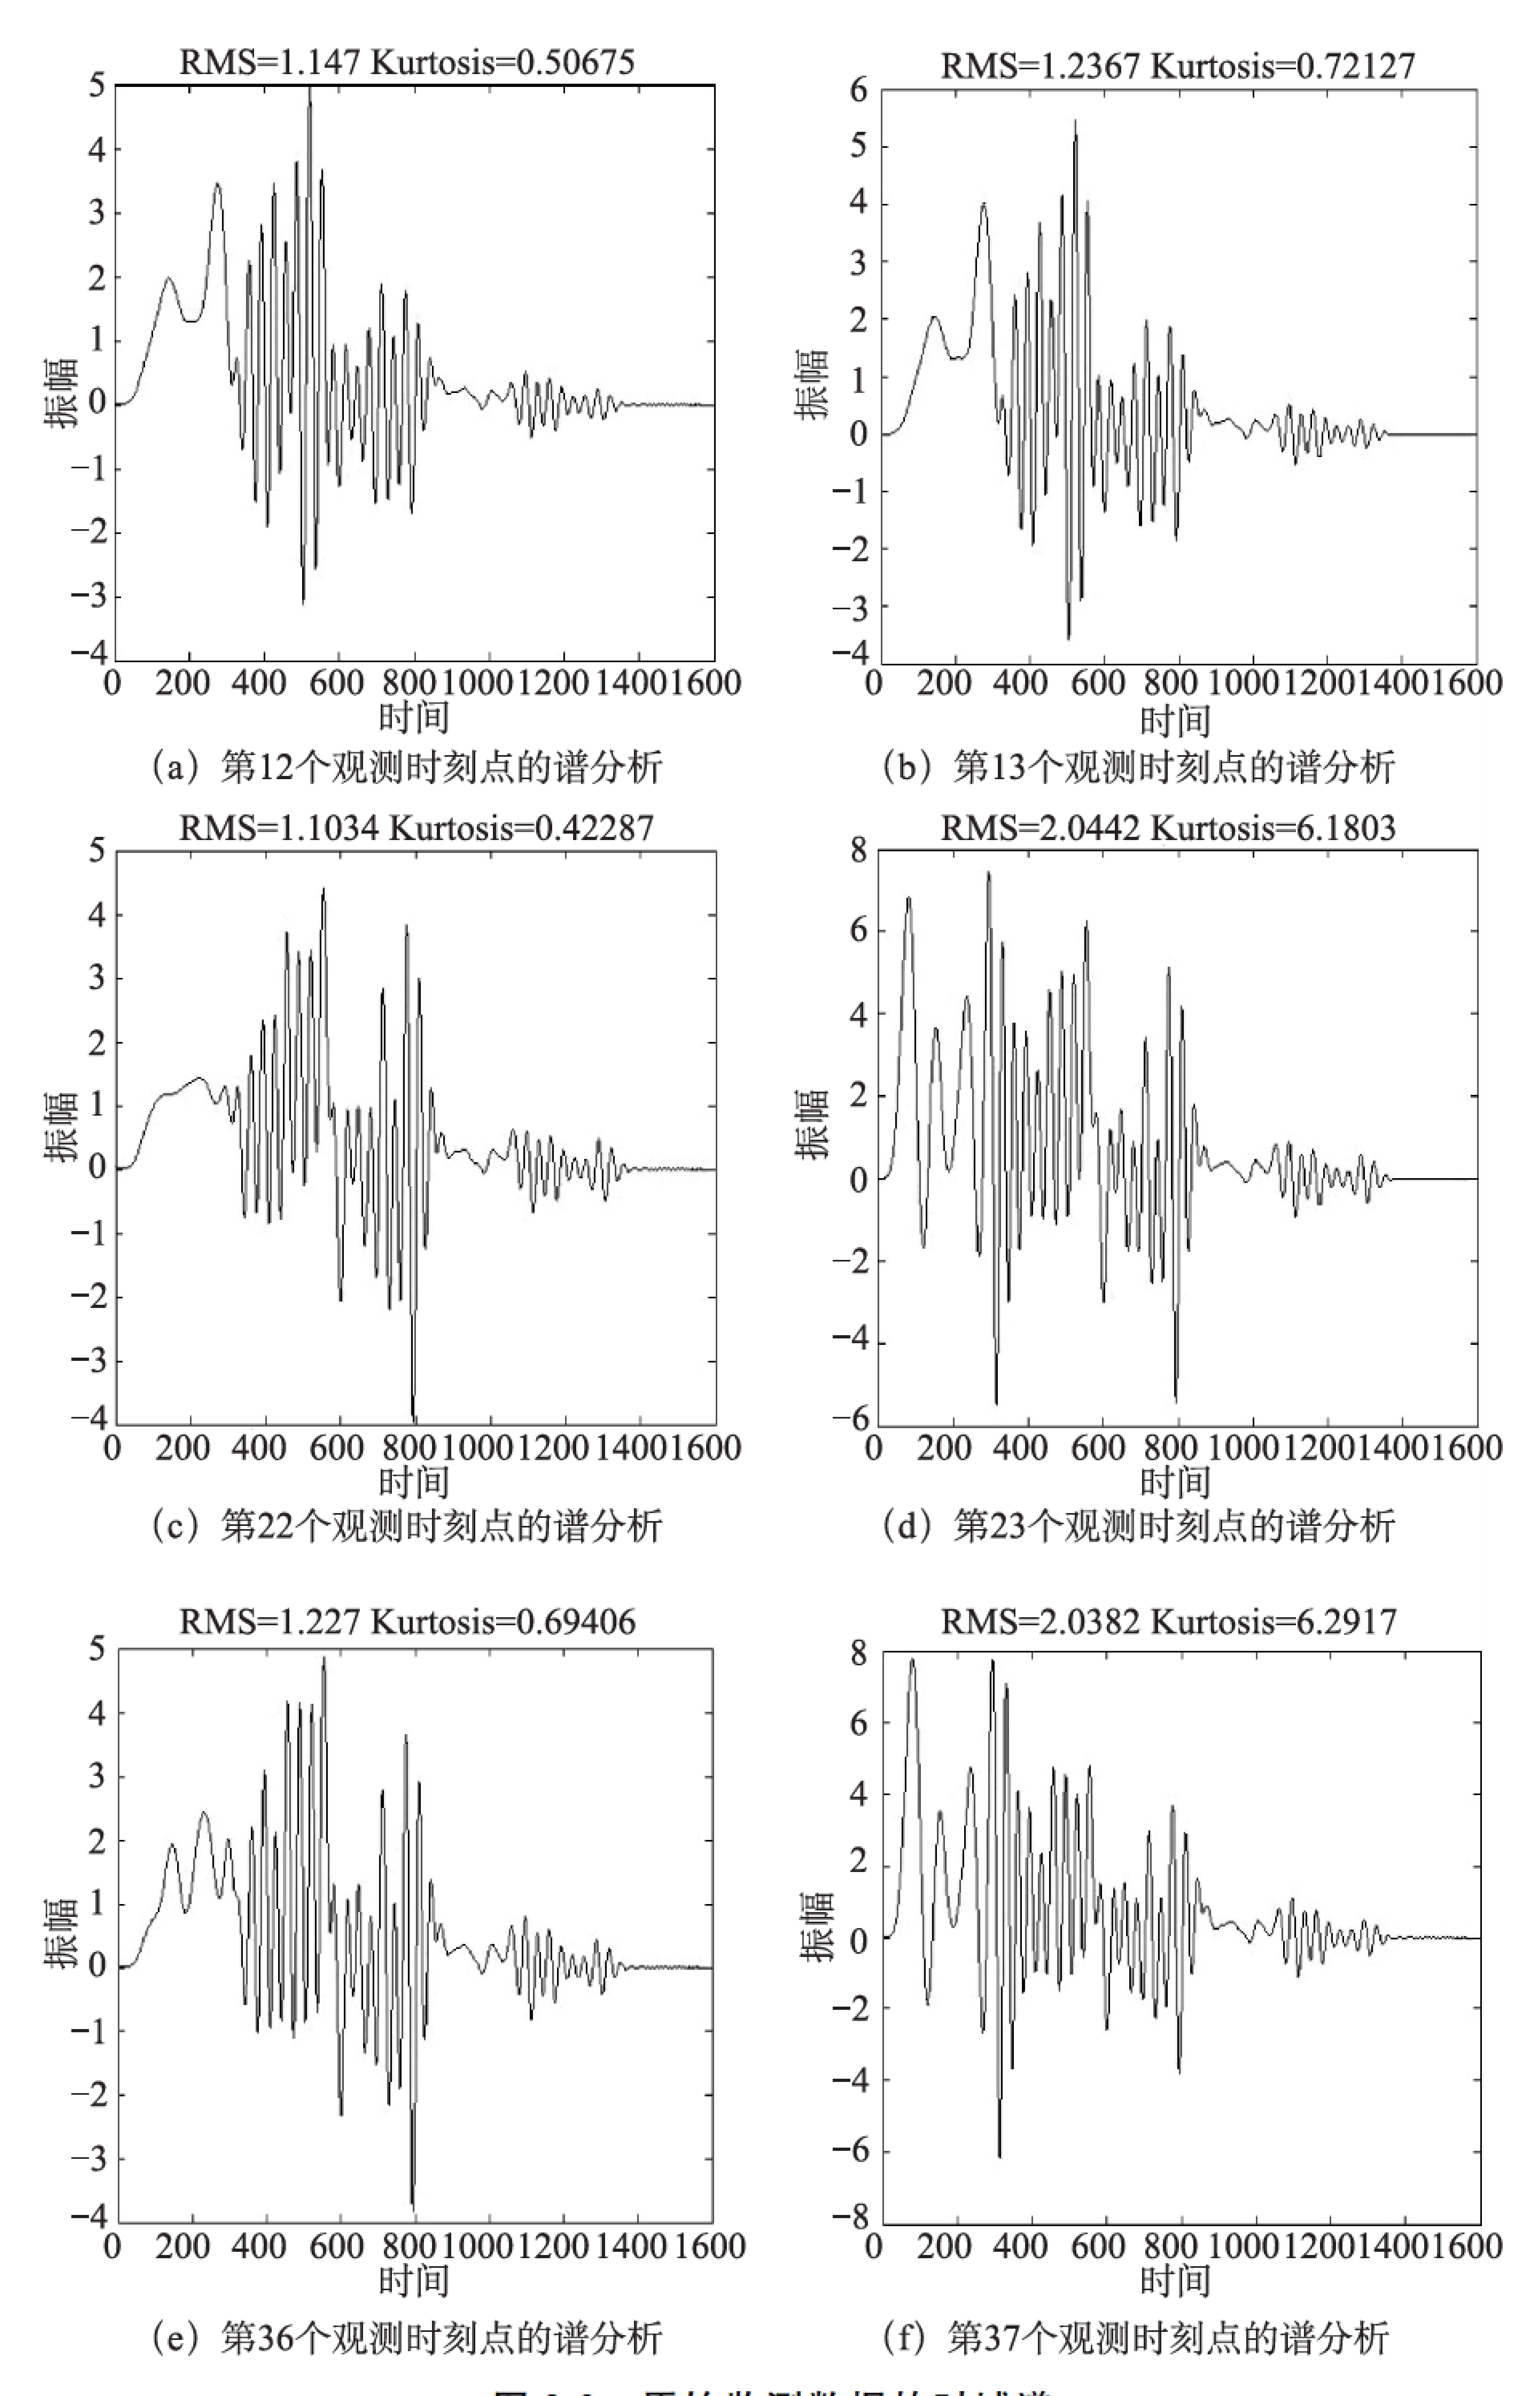


图 3-5　原始监测数据的 RMS 和 Kurtosis

液压泵的状态监测主要是用于预测它的健康状况。为了得到一个可靠的健康预测，需要被监测的特征应该对振动趋势非常敏感。我们用小波变换去除原始信号的噪声，并且做特征提取。不同于具有一个确定的基本函数的傅立叶变换，小波变换具有强大的结构和巨大的灵活性，是一个时间和频域的局域变换。并且，它能有效地从信号中提取信息，用伸缩和平移等运算功能对信号逐步进行多尺度细化，目的就是达到高频处时间细分，低频处频率细分，使小波变换能自动适应时频信号分析的要求，因而它是时频分析和处理非平稳信号的一种很好的工具。对于液压泵的健康预测，不止一个泵的特征被需要，因而基于全部监测信号，可以用小波振幅模式演示对于健康预测如何处理液压泵的特征。

在对监测信号进行特征提取后，可以获得模型的观测值，并且，这些观测值作为模型的输入来进行设备的健康状态预测。对应于图 3-6 的一些特殊的观测时刻点；表 3-5 展示了部分小波变换后的数据，小波变换后的数据输入在线健康预测的模型进行健康状态预测。表 3-5 分别是第 12 个样本观测时刻点、第 13 个样本观测时刻点、第 22 个样本观测时刻点、第 23 个样本观测时刻点、第 36 个样本观测时刻点、第 37 个样本观测时刻点的数据。



(a) 第12个观测时刻点的谱分析

(b) 第13个观测时刻点的谱分析

(c) 第22个观测时刻点的谱分析

(d) 第23个观测时刻点的谱分析

(e) 第36个观测时刻点的谱分析

(f) 第37个观测时刻点的谱分析

图 3-6　原始监测数据的时域谱

表 3-5　部分小波变化数据

监测时刻点(健康状态)					
12(s_1)	13(s_2)	22(s_2)	23(s_3)	36(s_3)	37(s_4)
2.251 0	2.411 6	2.438 6	39.024 3	2.621 0	44.122 4
5.860 4	5.682 8	5.386 5	3.743 9	3.819 9	5.838 0
10.639 9	5.882 8	6.480 9	11.227 0	10.441 5	9.511 1
9.384 4	6.122 6	6.832 3	6.805 5	6.265 7	7.384 1
7.901 5	7.902 0	7.822 3	9.544 8	7.896 6	9.115 1
6.438 7	9.133 9	8.279 4	14.368 5	13.286 7	15.277 7
18.533 0	5.373 4	6.240 2	10.305 3	8.243 5	7.912 0
11.855 5	7.609 4	7.224 7	10.044 0	10.095 1	9.354 7
2.349 0	3.129 4	3.038 7	4.264 6	3.799 2	5.161 3
2.715 4	3.437 7	3.034 4	4.257 3	3.874 4	5.247 2
3.553 0	4.366 8	4.363 9	6.169 8	5.044 3	6.010 2
3.307 7	4.038 4	3.772 6	5.334 9	4.337 4	5.118 5
7.876 1	9.115 0	8.822 0	8.723 0	7.539 5	8.469 8
5.607 2	10.655 5	10.381 4	12.195 6	10.100 6	10.229 7
4.510 9	6.842 3	7.709 0	9.057 7	6.707 0	6.902 4
6.938 6	15.307 9	16.965 3	25.246 6	17.359 3	17.156 6
0.038 5	0.039 8	0.047 0	0.053 6	0.041 7	0.053 8
0.057 0	0.063 5	0.078 7	0.060 0	0.055 0	0.056 1
0.049 4	0.077 4	0.086 7	0.086 1	0.069 9	0.121 8
0.052 4	0.076 9	0.072 8	0.062 6	0.053 6	0.073 4
0.180 6	0.203 4	0.203 9	0.239 2	0.188 3	0.330 7
0.192 4	0.231 7	0.244 7	0.312 6	0.264 0	0.370 8
0.062 2	0.084 3	0.096 3	0.116 4	0.093 2	0.150 6
0.127 4	0.214 3	0.222 5	0.307 6	0.241 7	0.283 2
2.184 9	2.998 7	2.821 1	4.081 7	3.641 3	5.109 2
1.881 8	2.591 4	2.202 5	3.002 1	2.805 4	3.818 7
1.080 6	1.562 8	1.582 5	1.786 5	1.547 0	1.913 8
1.485 5	1.758 5	1.570 7	2.295 4	1.978 4	2.545 8
0.234 3	0.288 6	0.305 1	0.303 1	0.242 2	0.394 1
0.522 6	0.734 8	0.735 6	1.057 3	0.884 8	1.046 0
0.925 0	1.466 6	1.612 6	1.716 9	1.400 8	1.707 0
0.813 9	1.664 3	1.837 8	2.417 2	1.698 5	1.808 6

3.3.3 模型参数估计

设备的健康改变机制，通常涉及几个设备的衰退健康状态。从设备的正常运行到设备发生故障，设备一般要经历几个衰退状态，并且，状态之间是相互联系的，且可以通过状态转移概率来决定状态之间的相互转移。

在案例分析中，液压泵有 4 个隐藏的健康状态，分别被定义为：好（Baseline）、中（Degradation 1）、差（Degradation 2）、坏（Failure）。对于状态间的转移关系如图 3-7 所示。

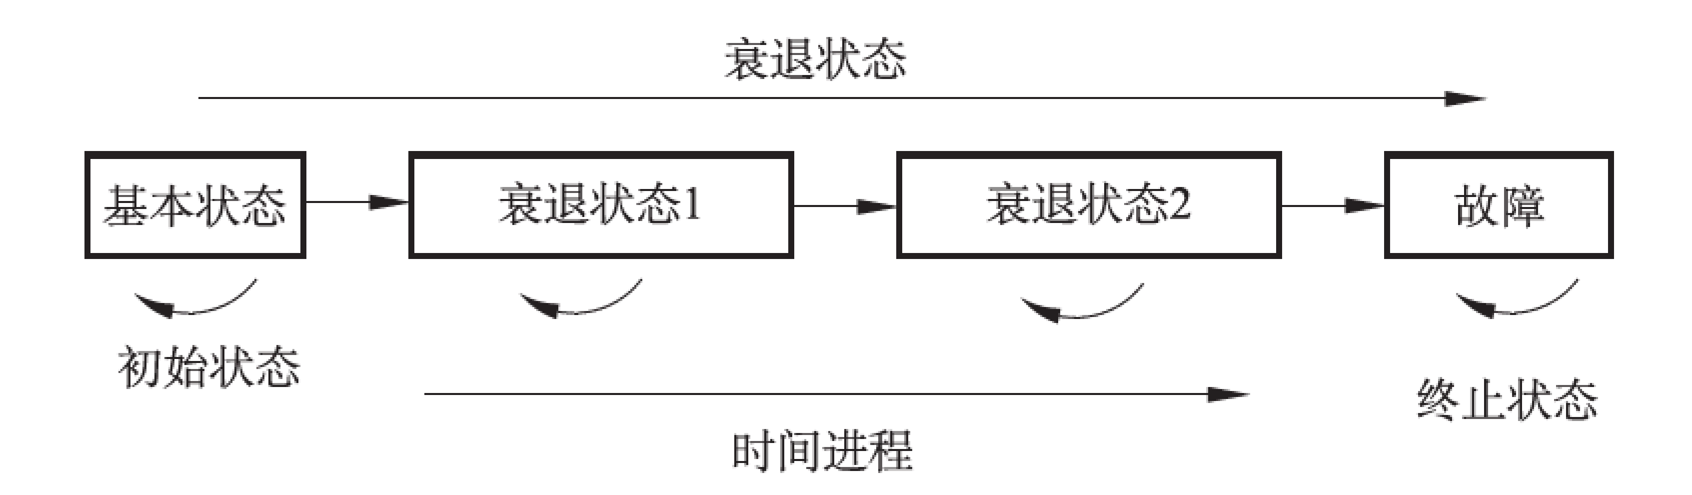


图 3-7 设备健康状态演化机制结构

设备在整个健康状态转换过程中，存在三个概率分布函数，分别是状态转移概率、状态驻留概率分布和观察值概率分布。

对于健康状态转移概率，假设 A_{ij} 表示状态转移概率矩阵第 i 行的第 j 个元素，则健康状态转移概率可以用下列方程来表示：

$$A_{ij} = \left((1-\lambda)m_{ij} + \lambda \bar{A}_{ij}\right) \Big/ \sum_{i=1}^{N}\left((1-\lambda)m_{ij} + \lambda \bar{A}_{ij}\right) \quad i,j = 1,2,3,4$$

在方程中，$\bar{A}_{ij}$ 的值来自维护专家的经验知识，m_{ij} 表示设备从健康状态 x_i 到健康状态 x_j 的转移次数（m_{i0} 表示状态 x_i 出现的计数统计），λ 被用来控制专家知识和实际观察之间的权重。

对于设备的健康状态驻留概率分布，可以用下列方程来表示：

$$p_i(d) = \frac{1}{\sigma(s_i)}\sqrt{\frac{2}{\pi}}\exp\left(-\frac{1}{2}\left(\frac{d-\mu(s_i)}{\sigma(s_i)}\right)\right) \quad i = 1,2,3,4$$

在方程中，$\sigma^2(s_i)$ 是第 i 个健康状态的方差，$\mu(s_i)$ 表示第 i 个健康状态的均值。

对于设备的观察值序列，对于每一个健康状态，两个高斯混合方程被用来表示观察值序列的概率分布，详细方程表示形式如下：

$$b_i(o_t) = \sum_{k=1}^{2}\omega_{ik}N(o_t, u_{ik}, U_{ik}) \quad i = 1,2,3,4; k = 1,2$$

在方程中，$N(o_t, u_{ik}, U_{ik}^2)$ 表示健康状态 s_i 的第 k 个混合高斯分布。u_{ik}，U_{ik}^2 和 ω_{ik} 分别表示健康状态 s_i 的第 k 个混合高斯分布的均值、方差和混合权重。并且，

$$\sum_{k=1}^{2} w_{ik} = 1 \quad w_{ik} \geqslant 0, i = 1,2,3,4; k = 1,2$$

因此，在线设备健康预测模型可以被描述为

$$\{A, B, D, \pi\} = \{a_{ij}, u_{ik}, U_{ik}^2, w_{ik}, \mu_i, \sigma_i, \pi_i, 1 \leqslant i, j \leqslant 4, 1 \leqslant k \leqslant 2\}$$

3.3.4 在线健康预测分析

对于案例中液压泵的健康预测分析，所有的寿命训练数据都是来自案例中的液压泵。一个具有四个健康状态好(Baseline)、中(Degradation 1)、差(Degradation 2)、坏(Failure)的 HSMM 被训练。其中，对于 4 个健康状态之间的状态转移概率，则是液压泵初始运转过程中的转移概率，对于每个健康状态的驻留时间的期望值，也可以经过 HSMM 的训练得到。对于健康状态转移概率和健康状态的驻留时间期望值分别如表 3-6 和表 3-7 所示。

表 3-6　健康状态间的原始转移概率

健康状态	好	中	差	坏
好	0.905 6	0.087 9	0.006 3	0.000 2
中	0	0.849 1	0.150 6	0.000 3
差	0	0	0.912 9	0.087 1
坏	0	0	0	1

表 3-7　健康状态期望驻留时间

健康状态	好	中	差	坏
驻留均值	10.454 9	9.792 3	11.337 5	—
驻留方差	1.938 8	0.979 2	1.241 5	—
$D(h_i)$	10.648 5	9.890 0	11.461 5	—

在案例中，我们用 s_1 表示健康状态 Baseline(好)，用 s_2 表示健康状态 Degradation 1(中)，用 s_3 表示健康状态 Degradation 2(差)，用 s_4 表示健康状态 Failure(坏)，用 S 表示健康状态的集合($s_l \in S$，其中，s_l 表示在第 l 个健康观测时刻点的健康状态)。在每一健康状态观测时刻点，液压泵的历史健康状态趋势如图 3-8 所示，其中，对于坐标轴 y，1 表示 s_1，2 表示 s_2，3 表示 s_3，4 表示 s_4。从图 3-8 中可以看出，液压泵的健康状态随着时间的变化，呈现一个衰退的趋势。

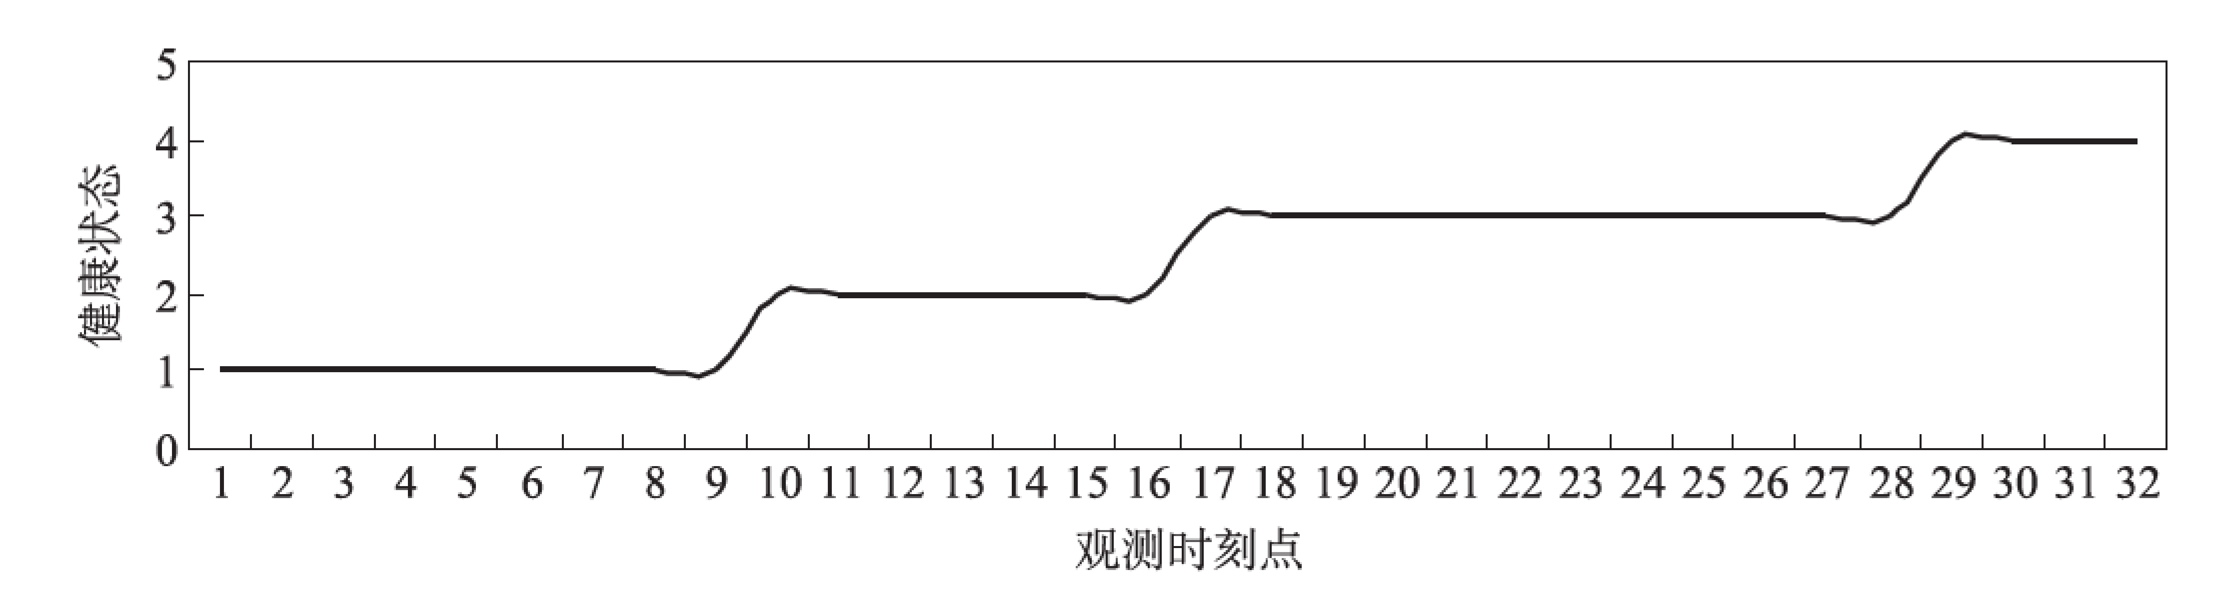


图 3-8　原始健康数据的状态演化

为验证本章提出的在线健康预测模型，在液压泵进入 Baseline 状态后，首先，我们通过 5 个观测时刻点的数据来计算液压泵的剩余寿命有效值，借以检验所提出模型的有效性。当液压泵停留在健康状态 Baseline 时，则可以计算液压泵的状态识别概率（$p(S_l=s_1|y_{1:l-1}), l=1,\cdots,5$），计算结果如表 3-8 所示。

表 3-8　状态识别概率（5 个观测时刻点）

观察时刻点（l）	状态概率	健康状态
1	0.882 1	s_1
2	0.855 6	
3	0.790 8	
4	0.774 4	
5	0.637 9	

然后，基于式（3-2）和式（3-3），计算这 5 个观测时刻点的液压泵的剩余寿命有效值。并且，根据液压泵的实际剩余寿命有效值，对预测值进行有效验证。液压泵的实际剩余寿命值和预测寿命值，以及两者之间的相对误差如表 3-9 所示。从表 3-9 中可以看出，对液压泵的在线健康预测来说，本章所提出的方法是非常有效的。其中，相对误差的计算公式如下：

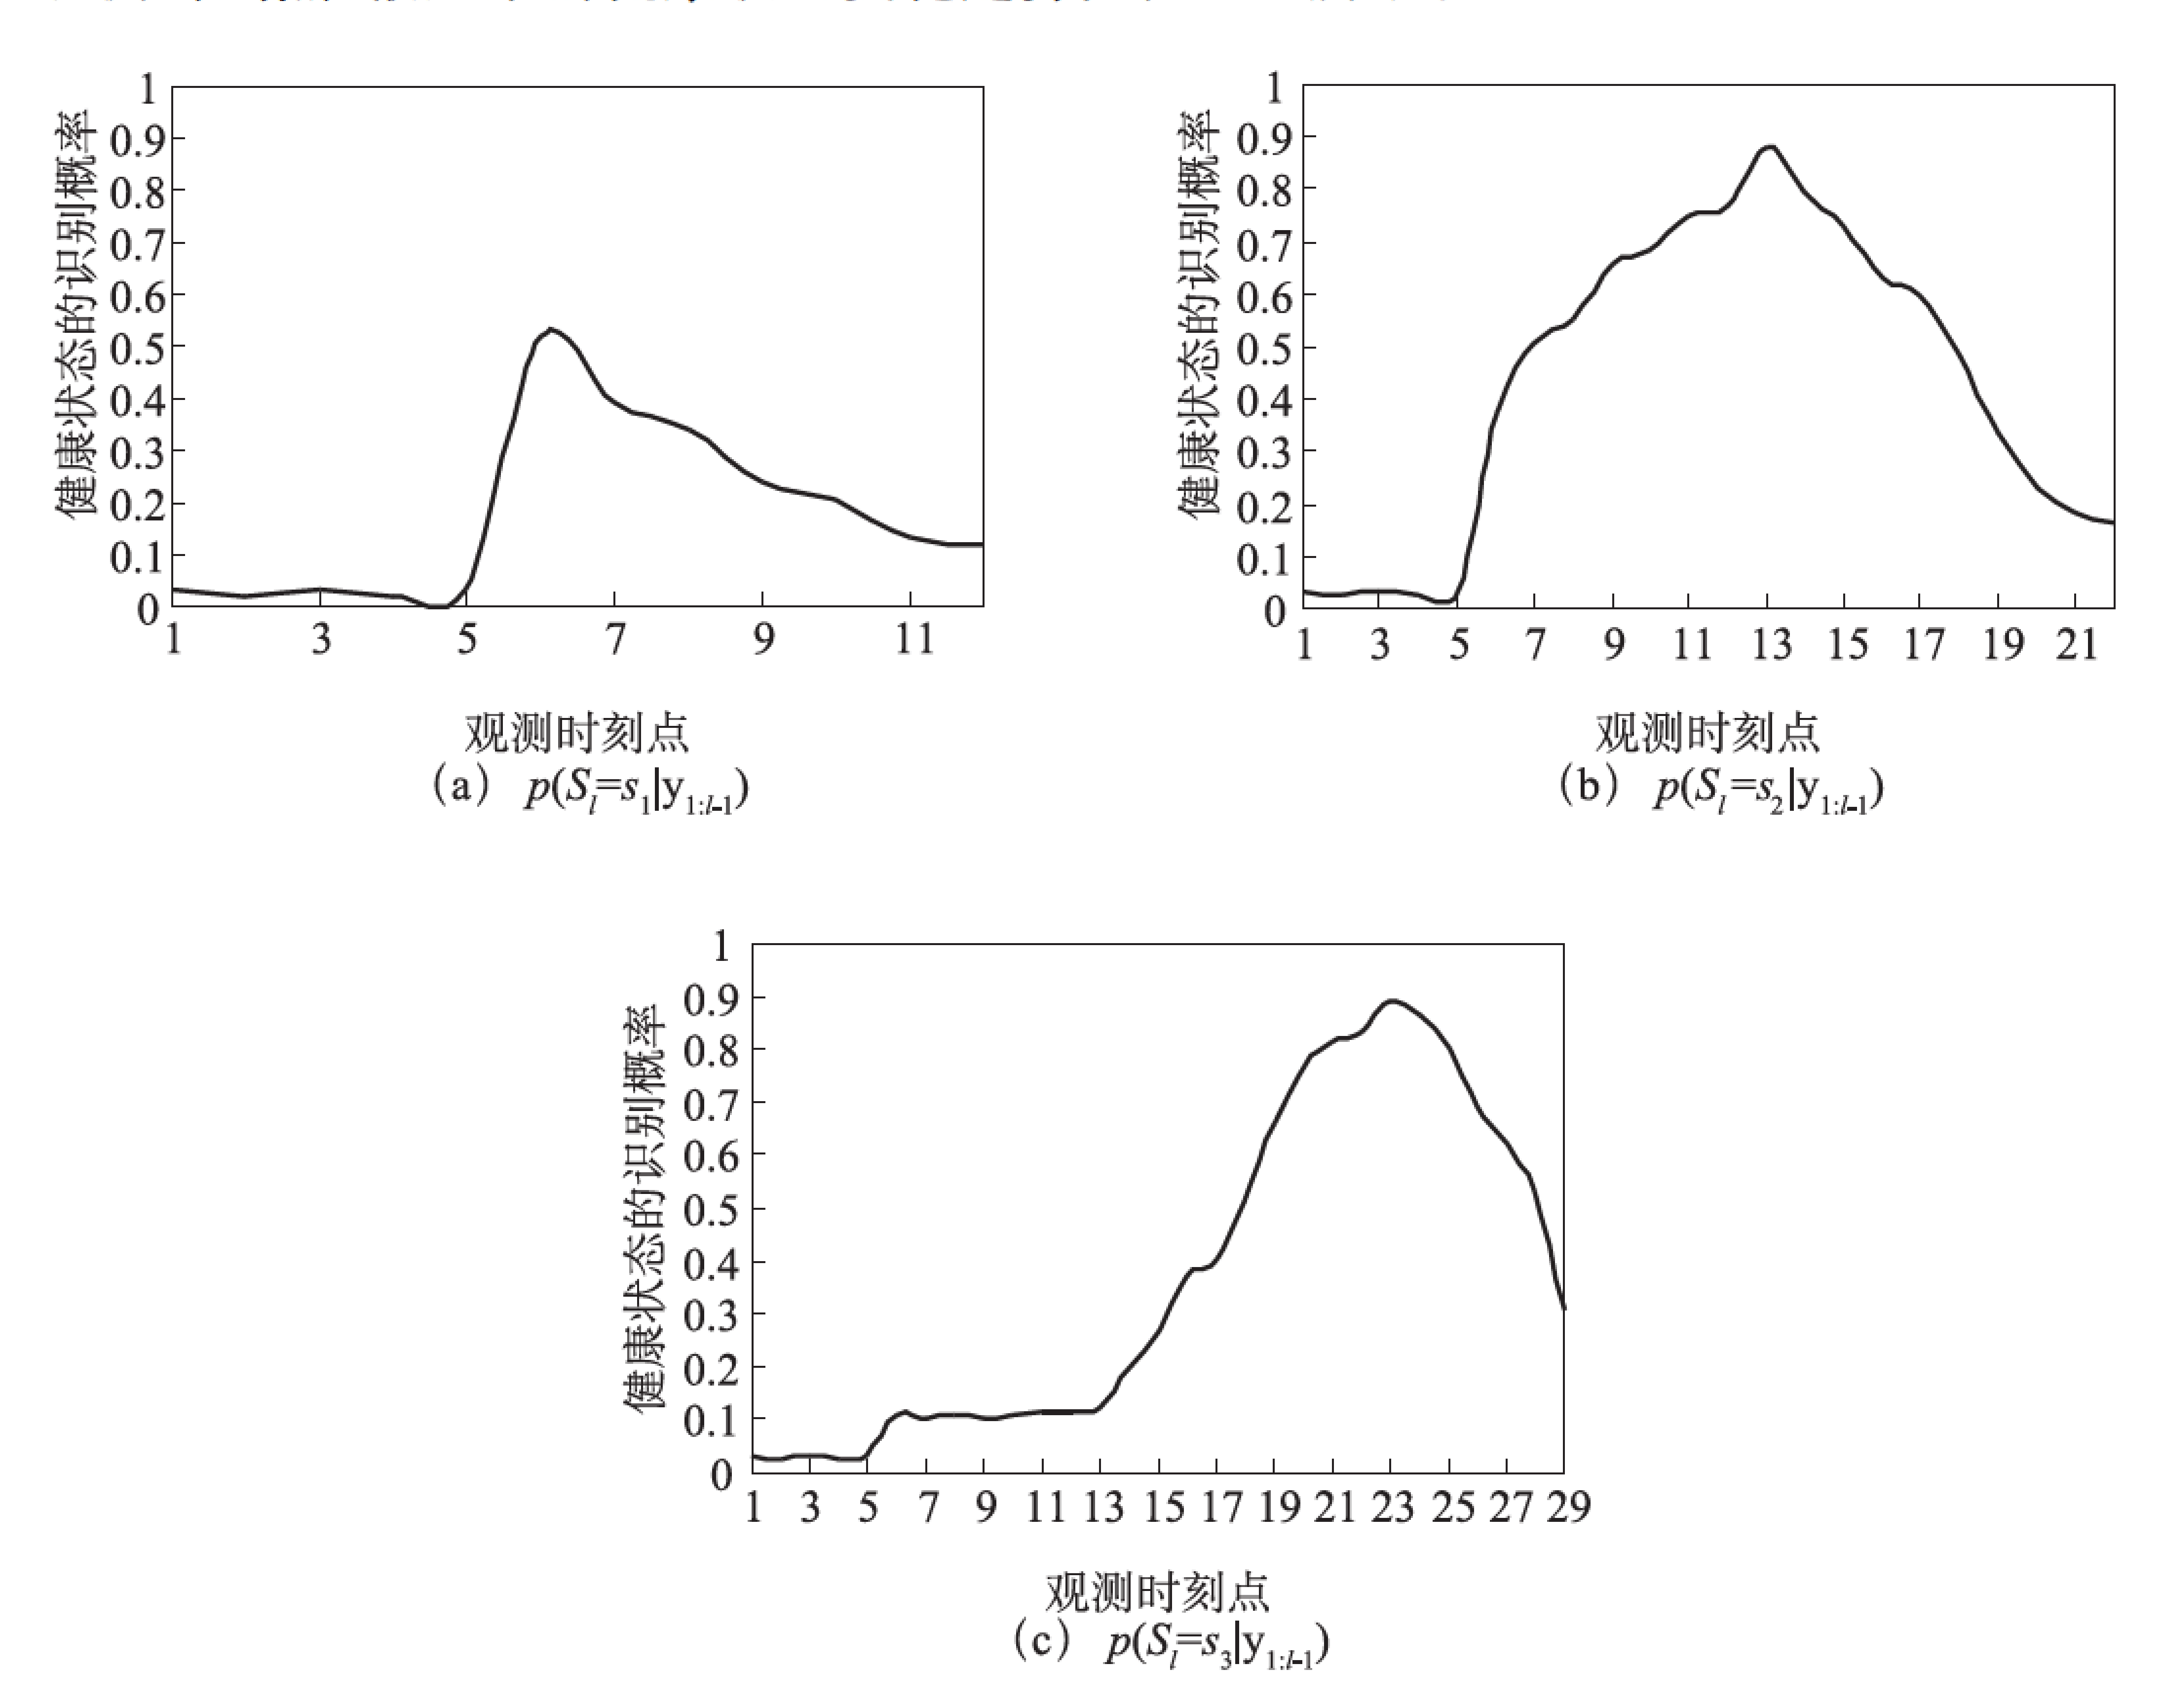
相对误差＝100％×|实际剩余寿命值－预测剩余寿命值|/实际剩余寿命值

表 3-9　预测剩余寿命值和实际剩余寿命值（5 个观测时刻点）

实际 RUL	计算 RUL	相对误差（％）
32.000 0	30.352 1	5.149 8
31.000 0	30.074 6	2.985 1
30.000 0	29.398 0	2.006 7
29.000 0	29.226 2	0.780 1
28.000 0	27.798 9	0.718 1

为了进一步验证本章所提出的方法对于液压泵的单监测信息在线健康预测是否具有更优的有效性，样本时刻点从 5 个观测时刻点扩大到 29 个观测时刻点。

首先，基于算法②，观测步数设置为 4（即 $h=4$，h 代表观测步数），则对于 29 个观测时刻点，液压泵的健康状态变化趋势如图 3-9 所示。



（a） $p(S_l=s_1|y_{1:l-1})$
（b） $p(S_l=s_2|y_{1:l-1})$
（c） $p(S_l=s_3|y_{1:l-1})$

图 3-9 健康状态概率改变趋势

然后，在获得液压泵的健康趋势以后，计算每个健康状态的识别概率，获得液压泵的健康状态转折点（见图 3-9）。图 3-9(a)、图 3-9(b)和图 3-9(c)分别代表了状态 s_1、s_2 和 s_3 的概率变化趋势。对于液压泵的健康状态，假设它们都是从健康状态识别概率达到最大值的观测时刻点开始的。从图 3-9(a)中可以看出，从第 6 个观测时刻点到第 12 个观测时刻点，液压泵的健康状态停留在健康状态 s_1；从图 3-9(b)中可以看出，从第 13 个观测时刻点到第 22 个观测时刻点，液压泵的健康状态停留在健康状态 s_2；从图 3-9(c)中可以看出，从第 23 个观测时刻点到第 29 个观测时刻点，液压泵的健康状态停留在健康状态 s_3。因此，对于每个健康状态观测时刻

点的健康状态识别概率被获得，如表 3-10 所示。

表 3-10 健康状态识别概率

观测时刻点	状态概率	健康状态	观测时刻点	状态概率	健康状态	观测时刻点	状态概率	健康状态
6	0.518 6	s_1	13	0.879 2	s_2	23	0.893 5	s_3
7	0.390 7		14	0.798 2		24	0.863 2	
8	0.341 3		15	0.732 8		25	0.801 4	
9	0.237 9		16	0.630 7		26	0.690 2	
10	0.209 2		17	0.596 1		27	0.618 7	
11	0.132 7		18	0.484 1		28	0.534 1	
12	0.120 3		19	0.338 4		29	0.306 2	
			20	0.230 6				
			21	0.186 4				
			22	0.166 4				

最后，基于式(3-2)，计算每一个 $\hat{D}(s_i^{(l)})$（l 代表了观测时刻点，$i=1,2,3$），获得每一个液压泵健康状态的期望驻留时间值。根据式(3-3)和 $\hat{D}(s_i^{(l)})$ 的值，可以获得液压泵在 29 个观测时刻点的剩余有效寿命值，表 3-11 显示了预测的剩余寿命有效值和液压泵的实际剩余寿命有效值，以及相对误差。对于预测值和实际值之间的比较结果如图 3-10。基于表 3-11 和图 3-10 可以看出，在预测的剩余寿命有效值和实际剩余寿命有效值之间的相对误差很小。因此，根据本章所提出的在线健康预测算法，可以很好地获得液压泵的健康状态，并且，预测的健康状态可以与实际的液压泵的健康状态相匹配。

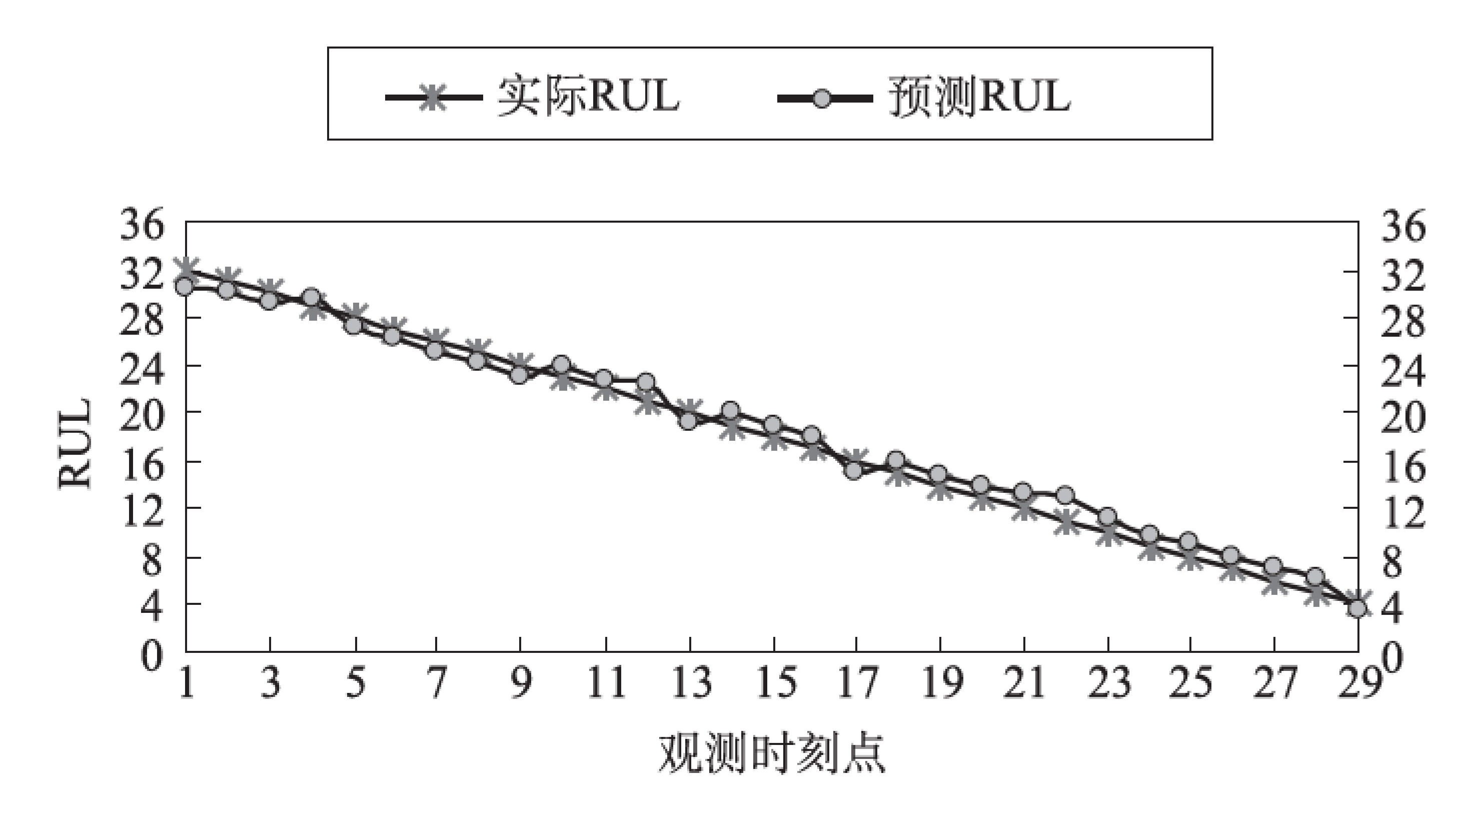


图 3-10 预测 RUL 与实际 RUL 的比较（提出的在线健康预测方法）

表 3-11 预测剩余寿命值和实际剩余寿命值(29 个观测时刻点)

实际 RUL	预测 RUL	相对误差(ε_i)	实际 RUL	预测 RUL	相对误差(ε_i)
32.000 0	30.352 1	5.149 8	17.000 0	17.513 4	3.019 9
31.000 0	30.074 6	2.985 1	16.000 0	17.174 3	7.339 3
30.000 0	29.398 0	2.006 7	15.000 0	16.077 6	7.183 7
29.000 0	29.226 2	0.780 1	14.000 0	14.651 6	4.654 2
28.000 0	27.798 9	0.718 1	13.000 0	13.596 0	4.584 4
27.000 0	26.551 5	1.661 0	12.000 0	13.162 5	9.687 8
26.000 0	25.214 2	3.022 4	11.000 0	12.966 7	17.879 0
25.000 0	24.698 2	1.207 1	10.000 0	10.130 1	1.300 6
24.000 0	23.617 5	1.593 7	9.000 0	9.786 6	8.740 1
23.000 0	23.316 5	1.376 2	8.000 0	9.085 8	13.572 0
22.000 0	22.517 2	2.350 7	7.000 0	7.824 7	11.780 8
21.000 0	22.387 3	6.606 2	6.000 0	7.015 1	16.917 6
20.000 0	19.946 9	0.265 5	5.000 0	6.055 8	21.116 6
19.000 0	19.153 6	0.808 4	4.000 0	3.471 0	13.224 2
18.000 0	18.513 0	2.849 9			

3.3.5 预测性能评估

通过案例分析,我们可以看出,本章所提出的在线健康预测算法可以很好地获得设备的健康状态。为了进一步验证提出方法的有效性,我们将分析 HSMM、基于联合多步算法的 HSMM 方法、基本多步算法的 HSMM、基于一步算法的 HSMM 方法在设备健康预测中的应用,来说明本章所提出的联合多步向前健康预测算法的优越性。上述四种方法的预测结果如表 3-12 所示。并且,该四种方法的预测趋势如图 3-11 所示。

表 3-12 四种方法的预测结果

实际 RUL	基于联合多步算法的 HSMM	基于多步算法的 HSMM	基于一步算法的 HSMM	HSMM
30.00	29.398	29.398 0	29.398 0	30.255 8
26.00	25.214 2	28.585 4	27.853 6	29.964 3
22.00	22.517 2	26.061 6	25.329 7	29.795 4
17.00	17.513 4	15.389 7	18.327 4	19.498 1
15.00	16.077 6	13.708 2	17.625 1	19.208 1
12.00	13.162 5	13.489 2	15.447 6	18.866 6
11.00	12.966 7	13.330 3	14.309 6	10.247 1
9.00	9.786 6	13.235 2	13.529 0	10.029 1
5.00	6.055 8	8.029 2	7.022 4	9.767 5

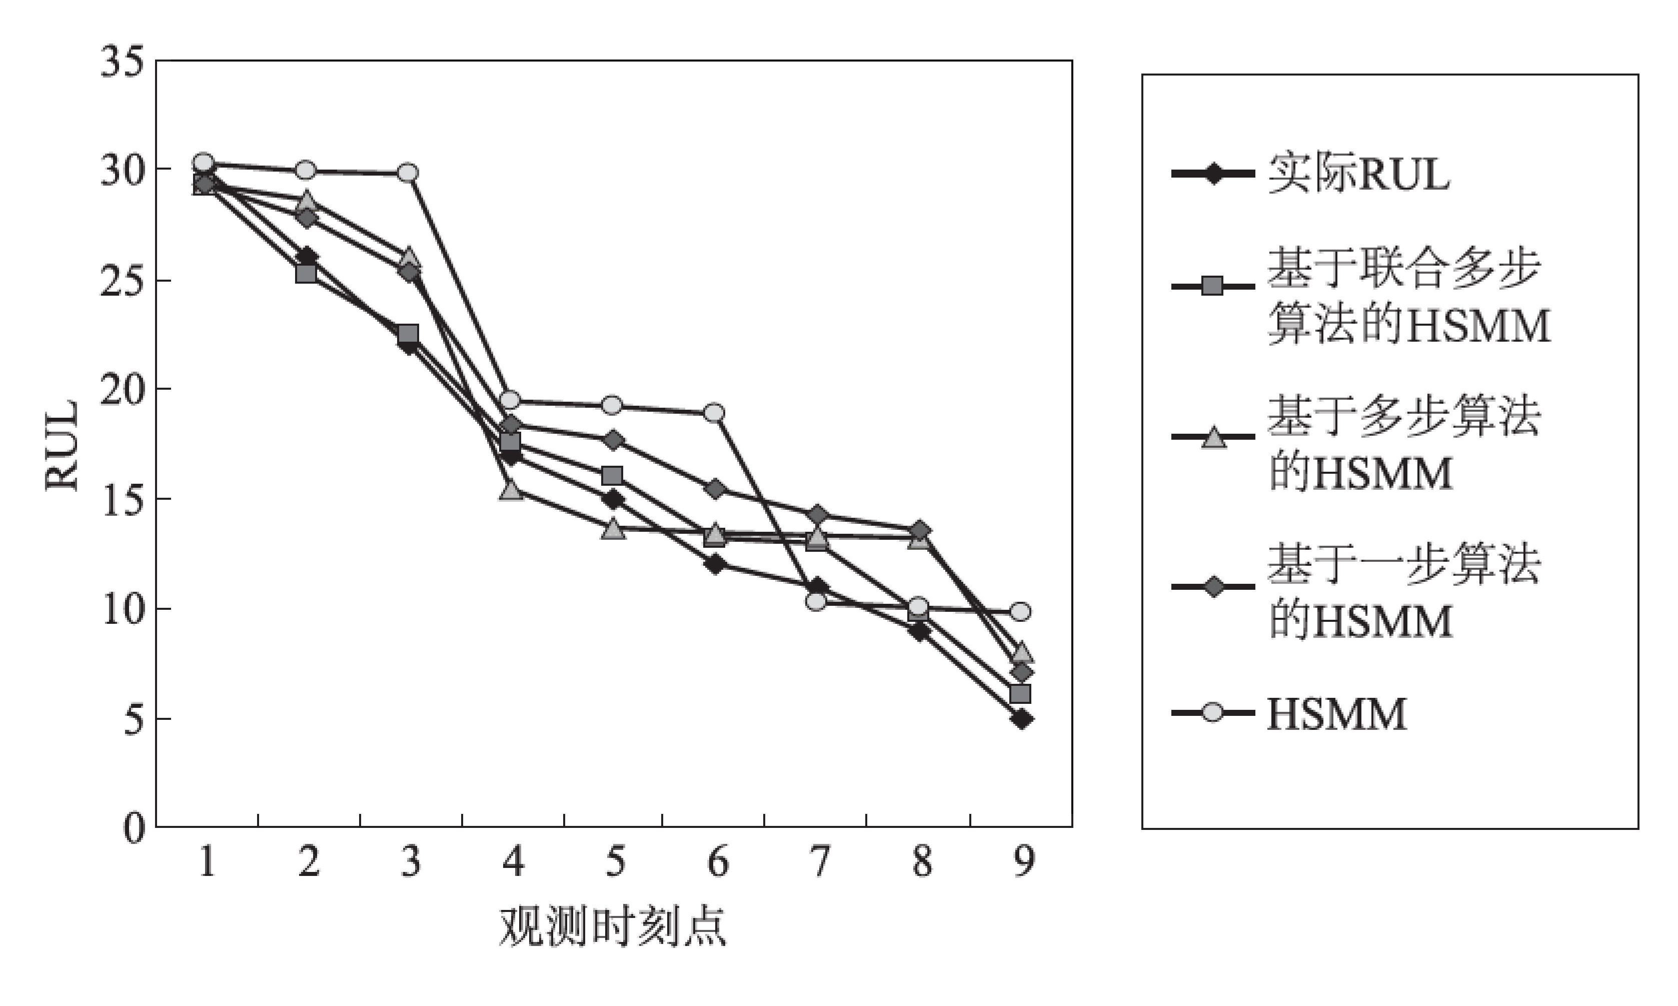


图 3-11　四种方法的预测趋势

基于表 3-12 和图 3-11，我们可以看出，提出的联合多步健康算法在设备在线健康预测方面优于 HSMM 方法、基于多步算法的 HSMM 方法和基于一步算法的 HSMM 方法。为了评估这四种方法的性能，分析了绝对误差标准和相对误差标准。绝对误差是指在预测过程中的物理误差，而相对误差是指相对于原有的实际值、预测值的优劣程度。对于绝对误差，我们主要分析均方根误差（RMSE）、方差绝对误差（VAE）和平均绝对误差（MAE）。对于相对误差，我们主要分析平均绝对相对误差（MARE）和方差相对误差（VRE）。并且，为了进一步评估这四种方法的性能，相关系数（R）也被分析。上述绝对误差和相对误差的表达式如下：

均方根误差（$\mathrm{E_{RMS}}$）：$\mathrm{E_{RMS}}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}\eta_i^2}$

平均绝对误差（$\mathrm{E_{MA}}$）：$\mathrm{E_{MA}}=\frac{1}{n}\sum_{i=1}^{n}\eta_i$

方差绝对误差（$\mathrm{E_{VA}}$）：$\mathrm{E_{VA}}=\frac{1}{n}\sum_{i=1}^{n}(\eta_i-\mathrm{E_{MA}})^2$

平均绝对相对误差（$\mathrm{E_{MAR}}$）：$\mathrm{E_{MAR}}=\frac{1}{n}\sum_{i=1}^{n}\varepsilon_i$

方差相对误差（$\mathrm{E_{VR}}$）：$\mathrm{E_{VR}}=\frac{1}{n}\sum_{i=1}^{n}(\varepsilon_i-\mathrm{E_{MAR}})^2$

相关系数(R)：$R=\dfrac{\sum_{i=1}^{n}(y_i-\bar{y})(\hat{y}_i-\bar{\hat{y}})}{\sqrt{\sum_{i=1}^{n}(y_i-\bar{y})^2}\sqrt{\sum_{i=1}^{n}(\hat{y}_i-\bar{\hat{y}})^2}}$

其中，i 代表了观察时刻点，n 是总的观测时刻点的数量，η_i 和 ε_i 分别表示在第 i 观察时刻点的绝对误差与相对误差。y_i 和 $\hat{y}_i$ 分别表示在第 i 观察时刻点的实际剩余寿命值与预测剩余寿命值。$\bar{y}$ 和 $\bar{\hat{y}}$ 分别表示了实际剩余寿命值的平均值与预测剩余寿命值的平均值。

基于上述六个误差标准，HSMM 方法、基于多步算法的 HSMM 方法、基于一步向前算法的 HSMM 方法和提出的联合多步健康预测算法的评估结果如表 3-13 所示。如果误差值越小，则代表着该方法在预测方面越精确。基于表 3-13 中的 RMSE、MAE、VAE、MARE 和 VRE 的值，我们可以看出，所提出的联合多步健康预测算法的预测精度优于 HSMM 方法、基于多步算法的 HSMM 方法和基于一步算法的 HSMM 方法。从相关系数来看，也说明了提出的联合多步健康预测算法的预测精优于 HSMM 方法、基于多步算法的 HSMM 方法和基于一步算法的 HSMM 方法。

表 3-13　四种方法的性能评估结果

预测方法	误差标准					
	RSME	MAE	VAE	MARE	VRE	R
基于联合多步算法的 HSMM	1.034 1	0.940 8	0.184 3	0.083 3	0.004 3	0.997 9
基于多步算法的 HSMM	2.636 6	2.359 4	1.384 8	0.157 1	0.009 3	0.962 5
基于一步算法的 HSMM	2.808 3	2.560 7	1.329 4	0.221 3	0.023 8	0.987 6
HSMM	4.371 7	3.570 9	6.360 4	0.294 6	0.080 3	0.942 0

对于整个案例，基于在线健康预测算法和可用的观测数据，可以进行单监测信息的在线健康预测。并且，我们从预测结果可以看出，所提出的联合多步向前健康预测算法在设备的在线健康预测方面具有很好的性能，包括预测精度和预测性能。进一步分析看出，所提出的联合多步向前健康预测算法与 HSMM 方法相比，在处理大量数据时，计算复杂性有所下降，所提出的联合多步向前健康预测算法的预测精度也优于 HSMM 方法[112,113]、基于多步向前算法的 HSMM 方法和基于一步向前算法的 HSMM 方法。所提出的联合多步向前健康预测算法也减少了计算存储空间。经过上述分析可以得出，在设备在线健康预测方面，所提出的联合多步向前

健康预测算法是非常有效的。

3.4 本章小结

本章基于 SMC 方法和退化 HSMM，提出了一个单监测信息的在线健康预测模型。在实际的应用过程中，某一个单一方法或者模型已经很难对设备进行有效的健康预测，因此，基于 HSMM 丰富的诊断与预测结构和 SMC 在线特征，结合了每个方法的优点，提出了一个新颖的联合多步向前健康预测算法，从而消除了单一方法所带来的缺点。并且，发展了在线设备剩余寿命预测模型，利用当前设备的健康状态信息，可以有效地计算设备剩余寿命预测值，获得设备健康发展趋势。通过算例的分析可知，在设备健康预测领域，所提出的联合多步向前在线健康预测算法，通过与 HSMM、多步向前算法和一步向前算法进行了比较，结果显示，本章所提出的联合多步向前在线健康预测算法，在预测精度、预测复杂性等方面，都具有很好的性能。



第 4 章 多监测信息的在线健康预测

4.1 引　言

当前,计算机技术高速发展,在军事领域和工业领域,多监测信息(多传感器信息)融合技术得到了广泛的关注与应用。对于多传感器信息融合技术的应用,可以有效避免单一传感器的局限性和信息不准确性,多传感器可以获取更多更准确的信息,基于这些信息,可以得出更精确的结论。多监测信息在战场监视、飞行器导航、遥感技术、目标识别、机器人、工业生产、图像处理及医疗诊断等不同领域已大量投入应用。

为了满足生产企业对设备使用的需求,在单监测信息在线健康预测的基础上,考虑多监测信息的在线健康预测。在设备实际使用过程中,需要发展一种以设备的健康状态为基础,不依赖于以前的统计数据的新的设备维护策略及设备的维护调度策略。因此,需要考虑设备的实际运行状态,为维护和维护调度的管理层提供有效维护活动和有效计划所需要的设备健康数据,在设备健康状态恶化之前,对设备进行实时的处理,以避免一些成本高昂的大修,降低设备的失效率,提高设备的利用率,降低设备的维护成本,提高企业的生产率。在此目标的基础上,有必要对

设备进行有效的健康预测,将基于多传感器获得有效的设备健康状态信息作为维护模型和维护调度模型的输入参数,从而有利于发展设备的维护模型。

基于单监测信息的在线健康预测方法,本章通过建立一种新颖的处理多监测信息的自适应隐半马尔可夫模型(AHSMM),对设备进行有效的健康预测。首先,对于退化 HSMM 的基本算法进行修正,获得了修正的 HSMM 基本算法,修正后的算法在处理多传感器信息时,可以有效地降低模型的计算复杂性和空间复杂性。其次,对于设备隐藏的衰退状态的识别,最大似然线性回归变换方法被用于训练 AHSMM 的输出概率分布和状态的驻留概率分布,从而可以有效地重新估计 AHSMM 的未知参数,AHSMM 被用来获得和计算设备健康状态间的转移概率和设备的健康状态的驻留时间。最后,基于 AHSMM,发展了一种健康预测模型预测多传感器的设备健康状态,并且估计设备的剩余有效寿命。

4.2 特征空间降维

在收集多传感的监测数据后,需要对原始数据进行预处理,并且,需要对预处理后的数据进行特征提取,从而形成一个数据的特征向量集合。在初始的特征提取中,会采集大量的数据特征值,而大量的特征向量具有高维性质,会造成某些特征向量非常相关,导致信息重叠的现象。因此,为了对基于多传感器的设备进行预测和降低数据冗余性,需要对数据进行降维处理,便于后续的数据分析,降低模型在预测过程中的计算复杂性。

在进行多传感器的设备健康预测方面,基于合理利用多传感器监测数据的目的,需要对监测数据进行降维操作和简化处理过程,降低多传感器监测数据的维数,便于数据进行处理与分析,虽然数据的维数降低了,但是,通过降维数据而获得的预测结果的精确度是不受影响的。本章应用多元统计方法 PCA 来对数据执行降维操作,通常用 PCA 考察模型多个变量之间的相互关联性,还可以应用监测数据的少数几个主成分描述模型多个变量之间的内部特征。在数据处理过程中,PCA 主要起到数据压缩及解释的作用。PCA 在进行数据降维操作过程中,具有对数据变异较小的变量方向进行省略,投射传感器检测数据到一个不大的空间,压缩

传感器监测数据的处理思想。PCA 在进行数据降维操作过程中的基本步骤如下。

（1）标准化多传感器的初始检测数据矩阵，在数量级或量纲上，将模型变量的影响去除。

（2）针对多传感器标准化的数据矩阵，执行协方差或相关矩阵的求解操作。

（3）针对获得的协方差或相关矩阵，执行特征根与特征向量的计算操作。

（4）对正交向量进行计算，从而来表征标准化后的输入数据，获得的正交向量即为主成分，因此，多传感器的原始监测数据可以被认为是主成分的线性组合。

（5）为了更好地分析每个向量，进行按重要程度排序主成分的操作。

（6）为了重新构造多传感器的原始监测数据的信息近似值，进行基于筛选准则保留较强主成分的操作。

4.3　设备在线健康预测方法

4.3.1　修正隐式半马尔可夫模型

对于 AHSMM，基本参数包括初始状态概率（π）、状态转移概率（A）、观察值概率（B）、状态驻留（D）。一个 AHSMM 可以被描述为 $\lambda=(\pi,A,B,D)$。对于一个给定的健康状态 i，则健康状态 i 的驻留是 d，A 是健康状态之间的转移概率矩阵。

与 HSMM 相似，AHSMM 也存在评估、识别和训练这三个基本问题。在 AHSMM 中，新的前向—后向变量被重新定义，发展了新的前向—后向算法。

为了降低 AHSMM 的计算复杂性，传统的 HSMM 基本算法需要进行改进。为了执行基本 HSMM 的改进，定义了一个前向变量 $\alpha_t(i,d)$，它表示在健康状态 i，并且已经存在驻留 $d_t(i,d)=d$ 的情况下，产生 $o_1,o_2,\cdots,o_t$ 的概率。在本章中，用 ε_t 表示当前健康状态 q_t 已经存在的状态驻留。

当（q_t,ε_t）取值为（i,d）的时候，半马尔可夫链将保持在当前健康状态 i 直到时间 t，并且，健康状态 i 已经存在状态驻留 d，在时间 $t+1$ 时，转移到其他健康状态。因此，对于 $1\leqslant t\leqslant T-1,d\in[1,D],i,j\in S$，可将一个前向变量定义为

$$\alpha_t(i,d)=p(o_1,o_2,\cdots,o_t,q_{[t-d+1:t]}=i\mid\lambda)=p[o_1^t,(q_t,\varepsilon_t)=(i,d)] \quad (4\text{-}1)$$

假定 $\alpha_t(i,d)$ 已经被确定，健康状态 i 已经存在状态驻留 d。如果当健康状态 i

结束的时候，产生观察值序列 $o_1, o_2, \cdots, o_t$，则需要满足下列条件。

（1）在当前健康状态产生观察值序列 $o_1, o_2, \cdots, o_d$ [即 $\alpha_t(i,d)$]。

（2）从健康状态 j 到健康状态 i 被选择（即 a_{ji}）。

（3）在健康状态 j 的状态驻留被选择[即 $P_j(\tau)$]。

（4）在健康状态 i 的 $o_{d+1}, o_{d+2}, \cdots, o_t$ 被省略。

则可以获得前向递归方程：

$$\alpha_t(i,d) = \begin{cases} \sum_{j=1, j\neq i}^{N} a_{ji} b_i(o_t) \left(\sum_{\tau=1}^{D} \alpha_{t-1}(j,\tau) p_j(\tau) \right) & d = 1 \\ \alpha_{t-1}(i,d-1) \prod_{s=1}^{d} b_i(o_{t-s+1}) & d > 1 \end{cases} \tag{4-2}$$

$$\alpha_1(i,d) = \pi_i b_i(o_1) p_i(d) \tag{4-3}$$

$$\alpha_\tau(i,d) = 0 \qquad \tau < 1 \tag{4-4}$$

其中，D 表示所有健康状态中的最大状态驻留。

在式(4-2)中，为了降低 AHSMM 的前向方程的计算复杂性，需要修正观察值概率表达式，因此，观察值概率的修正递归关系可表示为

$$U_{t,i}(s) = \begin{cases} \prod_{s=1}^{d} b_i(o_{t-s+1}) = b_i(o_{t-s+1}) U_{t,i}(s-1) & s = 1,2,\cdots,d, d \in [1,D] \\ U_{t,i}(0) = 1 \end{cases} \tag{4-4}$$

给定模型 λ，则观察值 O 的概率方程见下式：

$$p(o_1^T \mid \lambda) = \sum_{i=1}^{N} \sum_{d=1}^{D} \alpha_T(i,d) \tag{4-5}$$

在这个情况下，$\alpha_T(i,d)$ 定义为

$$\alpha_T(i,d) = p(o_1, o_2, \cdots, o_t, q_{[T-d+1:T]} = i \mid \lambda) \tag{4-6}$$

因此，$p(o_1^T \mid \lambda)$ 是所有 $\alpha_T(i,d)$ 的和。

与前向变量相似，对于 $1 \leqslant t \leqslant T-1, d \in [1,D], i,j \in S$，一个后向变量可以定义为

$$\beta_t(i,d) = p(o_{t+1}, o_{t+2}, \cdots, o_T \mid q_{[t-d+1:t]} = i, \lambda) = p(o_{t+1}^T \mid (q_t, \varepsilon_t) = (i,d)) \tag{4-7}$$

假定后向变量 $\beta_t(j,d)$ 被确定，健康状态 i 已经存在状态驻留 d。对所有健康状态和所有可能的状态驻留求和，则后向递归方程可以被表示为

$$\beta_t(i,d) = \beta_{t+1}(j,d+1)\prod_{s=1}^{d} b_i(o_{t+s}) + \left(\sum_{j=1,j\neq i}^{N} \beta_{t+1}(j,1)a_{ij}\right)p_i(d)b_j(o_{t+1}) \tag{4-8}$$

$$\beta_T(i,d) = 1 \tag{4-9}$$

$$\beta_\tau(i,d) = 0 \quad \tau > T \tag{4-10}$$

为了估计健康状态 q_t 和重新估计模型 λ 的参数，基于上面定义的前后向变量，定义观察值序列和在给定时间从健康状态 i 到健康状态 $j(i\neq j)$ 的一个转移过程的联合概率，因此，给定模型 λ 和观察值序列 $O_{1:T}$，当前处于健康状态 i（已存在状态驻留 d），$\xi_t^d(i,j)$ 表示观察值 $O_{1:T}$ 和在时间 t 从健康状态 i 转移到健康状态 j 的概率的联合概率。具体的方程如下：

$$\begin{aligned}
\xi_t^d(i,j) &= p(o_{1:T}, q_{t-1} = i, q_t = j \mid \lambda) \\
&= p(o_{1:t-1}, q_{t-1} = i \mid \lambda)p(o_{t:T}, q_t = j \mid \lambda, q_{t-1} = i, O_1^t) \\
&= \alpha_{t-1}(i,d)p(o_{t:T}, q_t = j \mid \lambda, q_{t-1} = i) \\
&= \alpha_{t-1}(i,d)p(q_t = j \mid \lambda, q_{t-1} = i)p(o_{t:T} \mid q_t = i, \lambda) \\
&= \alpha_{t-1}(i,d)a_{ij}p(o_{t:T} \mid q_t = i, \lambda) \\
&= \alpha_{t-1}(i,d)\left(\sum_{j=1,j\neq i}^{N} \beta_t(j,1)a_{ij}\right)p_i(d)b_j(o_t)
\end{aligned} \tag{4-11}$$

为了从观察值序列 $O_{1:T}$ 估计健康状态，给定模型 λ 和观察值序列 $O_{1:T}$，当前处于健康状态 i（已存在状态驻留 d），定义健康状态 i 和 $O_{1:T}$ 的联合概率 $\gamma_t^d(i)$，基于方程(4-11)，对于 $\gamma_t^d(i)$ 的递归方程可以解得

$$\begin{aligned}
\gamma_t^d(i) &= p(q_t = i \mid o_{1:T}, \lambda) \\
&= p(q_{t-1} = i, q_t = i \mid o_{1:T}, \lambda) + p(q_{t-1} \neq i, q_t = i \mid o_{1:T}, \lambda) \\
&= p(q_{t-1} = i \mid o_{1:T}, \lambda) - p(q_{t-1} = i, q_t \neq i \mid o_{1:T}, \lambda) + \\
&\quad p(q_{t-1} \neq i, q_t = i \mid o_{1:T}, \lambda) \\
&= \gamma_{t-1}(i) - \sum_{j=1,j\neq i}^{N} \xi_t(i,j) + \sum_{j=1,j\neq i}^{N} \xi_t(j,i) \\
&= \gamma_{t-1}(i) - \sum_{j=1,j\neq i}^{N} (\xi_t(i,j) - \xi_t(j,i))
\end{aligned} \tag{4-12}$$

$$\gamma_1^d(i) = \sum_{d=1}^{D} \alpha_1(i,d) \quad t > 1 \tag{4-13}$$

因此，基于 Viterbi 算法，健康状态 q_t 的最大后验估计可以通过以下方程获得：

$$\hat{q}_t = \arg\max_{i\in S} p(q_t = i \mid o_{1:T},\lambda) = \arg\max_{i\in S} \gamma_t^d(i) \tag{4-14}$$

给定观察值 $O_{1:T}$，初始状态分布 π 的重估方程可以根据下列方程获得：

$$\hat{\pi}_i = \frac{\gamma_1^d(i)}{\sum_{i=1}^{N} \gamma_1^d(i)} \tag{4-15}$$

状态转移概率的重估方程式是从健康状态 i 转移到健康状态 j 的期望转移次数与从健康状态 i 出发的期望转移次数的比值，具体表现为

$$\hat{a}_{ij} = \frac{\sum_{t=1}^{T}\sum_{d=1}^{t} \xi_t^d(i,j)}{\sum_{t=1}^{T}\sum_{d=1}^{t} \gamma_t^d(i)} \tag{4-16}$$

通过初始状态概率分布 $\{\pi_i\}_{1:N}$、状态转移概率 $\{a_{ij}\}_{1:N,i\neq j}$、状态输出概率分布 $\{b_i(\cdot)\}_{1:N}$ 和状态驻留概率分布 $\{p_i(\cdot)\}_{1:N}$，一个 HSMM 模型 λ 可以被确定。对于健康状态 i，状态输出概率分布是均值为 μ_i 和方差矩阵为 $\sum_i$ 的高斯分布，状态驻留概率分布是均值为 m_i 和方差为 ${\sigma_i}^2$ 的高斯分布。

$$b_i(O) = N(O;\ \mu_i,\ \Sigma_i) \tag{4-17}$$

$$p_i(d) = N(d;\ m_i,{\sigma_i}^2) \tag{4-18}$$

基于 Baum-Welch 算法，参数集合 λ 的重估方程表示为

$$\bar{u}_i = \frac{\sum_{t}^{T}\sum_{d}^{t} \gamma_t^d(i) \sum_{l=t-d+1}^{t} o_l}{\sum_{t}^{T}\sum_{d}^{t} \gamma_t^d(i) d} \tag{4-19}$$

$$\bar{\sum}_i = \frac{\sum_{t}^{T}\sum_{d}^{t} \gamma_t^d(i) \sum_{l=t-d+1}^{t} (o_l - \bar{u}_i)(o_{l_s} - \bar{u}_i)^T}{\sum_{t}^{T}\sum_{d}^{t} \gamma_t^d(i) d} \tag{4-20}$$

$$\bar{m}_i = \frac{\sum_{t}^{T}\sum_{d}^{t} \gamma_t^d(i) d}{\sum_{t}^{T}\sum_{d}^{t} \gamma_t^d(i)} \tag{4-21}$$

$$\bar{\sigma}_i = \frac{\sum_{t}^{T}\sum_{d}^{t} \gamma_t^d(i)(d - \bar{m}_i)^2}{\sum_{t}^{T}\sum_{d}^{t} \gamma_t^d(i)} \tag{4-22}$$

基于方程(4-19)和方程(4-20),观察值概率密度函数可以被获得:

$$\bar{b}_i(O) = N(O;\bar{\mu}_i, \bar{\sum}_i) \tag{4-23}$$

基于方程(4-21)和方程(4-22),驻留概率密度函数可以被获得:

$$\bar{p}_i(d) = N(d;\bar{m}_i,\bar{\sigma}_i) \tag{4-24}$$

4.3.2 自适应隐式半马尔可夫模型

对设备来说,如果采用多个传感器进行监测,从而产生多传感器的监测信息,健康预测就可以达到更好的性能。由于各种传感器的差异,数据信息需要一种有效的融合。因此,提出了基于 HSMM 的自适应训练算法。自适应训练算法的基本思想是使用最大似然线性回归(MLLR)变换来处理多个传感器之间的差异。同时,采用 MLLR 变换集合训练了一个规范模型。

AHSMM 充分利用了基于 HSMM 的基本修正算法,包括前后向算法、Viterbi 算法、Baum-Welch 算法和单监测信息预测算法。通过规范模型对状态输出和驻留分布的均值向量进行线性变换,从而可以获得传感器 s 的状态输出和驻留分布的均值向量。

$$b_i(o^{(s)}) = N(O;\ \eta^{(s)}\mu_i + \xi^{(s)},\ \sum_i) \tag{4-25}$$

$$p_i(d) = N(d;\delta^{(s)}m_i + \psi^{(s)}, \sigma_i^{\ 2}) \tag{4-26}$$

其中,$[\eta^{(s)}, \xi^{(s)}]$是传感器 s 的 $n\times(n+1)$维的状态输出概率分布变换矩阵,$[\delta^{(s)}, \psi^{(s)}]$是传感器 s 的 1×2 维的状态驻留概率分布变换矩阵。$\eta^{(s)}$ 是 $n\times n$ 维的矩阵,$\xi^{(s)}$是 n 维的向量。$[\mu_i, 1]^T$是$(n+1)$维的向量,$[m_i, 1]^T$是 2 维的向量。

让 S 表示传感器个数,$O=(O^{(1)},\cdots,O^{(s)})$表示监测数据,$O^{(s)}=(o_{1s},\cdots,o_{Ts})$表示长度为 Ts 的传感器 s 的监测数据。并且,在 AHSMM 中,最优模型参数集合 λ 和变换矩阵 Ω 是被联合估计的,因此,基于 Baum-Welch 算法的参数集合 λ 的重估方程为

$$\bar{\mu}_i = \frac{\sum_s^S \sum_t^{Ts} \sum_d^t \gamma_t^d(i)\, \eta^{\overline{(s)}\ T} \sum_i^{-1} \sum_{l=t-d+1}^t (o_{ls} - \xi^{\overline{(s)}})}{\sum_s^S \sum_t^{Ts} \sum_d^t \gamma_t^d(i) d\, \eta^{\overline{(s)}\ T} \sum_i^{-1} \eta^{\overline{(s)}}} \tag{4-27}$$

$$\bar{\sum}_i = \frac{\sum_s^S \sum_t^{Ts} \sum_d^t \gamma_t^d(i) \sum_{l=t-d+1}^t (o_{ls} - \mu_i\overline{(s)})(o_{ls} - \mu_i\overline{(s)})^T}{\sum_s^S \sum_t^{Ts} \sum_d^t \gamma_t^d(i) d} \tag{4-28}$$

$$\bar{m}_i = \frac{\sum_{s}^{S}\sum_{t}^{Ts}\sum_{d}^{t}\gamma_t^d(i)\,\delta^{\bar{(s)}}(d-\psi^{\bar{(s)}})}{\sum_{s}^{S}\sum_{t}^{Ts}\sum_{d}^{t}\gamma_t^d(i)\,\delta^{\bar{(s)}\,2}} \tag{4-29}$$

$$\bar{\sigma}_i = \frac{\sum_{s}^{S}\sum_{t}^{Ts}\sum_{d}^{t}\gamma_t^d(i)\,(d-m_i\bar{}(s))^2}{\sum_{s}^{S}\sum_{t}^{Ts}\sum_{d}^{t}\gamma_t^d(i)} \tag{4-30}$$

其中，$\mu_i\bar{}(s)=\eta^{\bar{(s)}}\bar{\mu}_i+\xi^{\bar{(s)}}$，$m_i\bar{}(s)=\delta^{\bar{(s)}}\bar{m}_i+\psi^{\bar{(s)}}$。

假定 $Y^{(s)}=[\eta^{(s)},\xi^{(s)}]$ 和 $X^{(s)}=[\delta^{(s)},\psi^{(s)}]$。让 $\boldsymbol{\Omega}=(\Omega^{(1)},\cdots,\Omega^{(S)})$ 表示变换矩阵，$\boldsymbol{\Omega}^{(s)}=(Y^{(s)},X^{(s)})$ 表示变换矩阵 $\boldsymbol{\Omega}^{(s)}$。对于变换矩阵 $\boldsymbol{\Omega}^{(s)}$，基于 Baum-Welch 算法的重估方程为

$$\begin{aligned} X^{\bar{(s)}} &= [\delta^{\bar{(s)}},\psi^{\bar{(s)}}] \\ &= \left(\sum_{t}^{Ts}\sum_{r}^{R}\sum_{d}^{t}\frac{\gamma_t^d(r)d}{\sigma_r^2}\varphi_r^T\right)\left(\sum_{t}^{Ts}\sum_{r}^{R}\sum_{d}^{t}\frac{\gamma_t^d(r)d}{\sigma_r^2}\varphi_r\varphi_r^T\right)^{-1} \end{aligned} \tag{4-31}$$

$$\begin{aligned} \mathbf{Y}^{\bar{(s)}} = [\eta^{\bar{(s)}},\xi^{\bar{(s)}}] &= \left(\sum_{t}^{Ts}\sum_{r}^{R}\sum_{d}^{t}\gamma_t^d(r)\sum\nolimits_r^{-1}\sum_{l=t-d+1}^{t}o_l\varepsilon_r^T\right) \\ &\left(\left(\sum_{t}^{Ts}\sum_{r}^{R}\sum_{d}^{t}\frac{\gamma_t^d(r)d}{\sum_r(k)}\varepsilon_r\varepsilon_r^T\right)^{-1}\right)^T \end{aligned} \tag{4-32}$$

其中，$\boldsymbol{\varphi}_i=[m_i,1]^T$，$\boldsymbol{\varepsilon}_i=[\mu_i^T,1]^T$。$R$ 代表了分享相同变化矩阵的分布数。$\sum_r(k)$ 代表了矩阵 $\sum_r$ 的第 k 个元素。

因此，基于 Viterbi 算法和单监测信息健康预测算法，重新估计状态 q_t 的最大后验估计。

$$\hat{q}_t = \arg\max_{\lambda} p(O\mid\lambda) = \arg\max_{\lambda}\prod_{s=1}^{S}p(O^s\mid\lambda) \tag{4-33}$$

上述内容描述了 HSMM 的自适应训练技术。对于设备健康预测，来自不同传感器的信息源往往在决策中扮演不同的角色。在 AHSMM，通过使用基于 HSMM 的最大似然线性回归的适应性，自适应训练进行了一个规范模型的输出和状态驻留分布的传感器标准化。在提出的方法中，解决了多传感器监测数据的有效融合问题，使用基于 HSMM 的自适应训练算法来处理每个传感器信息的有效融合。具有多传感器信息的 AHSMM 健康预测的总体框架如图 4-1 所示。

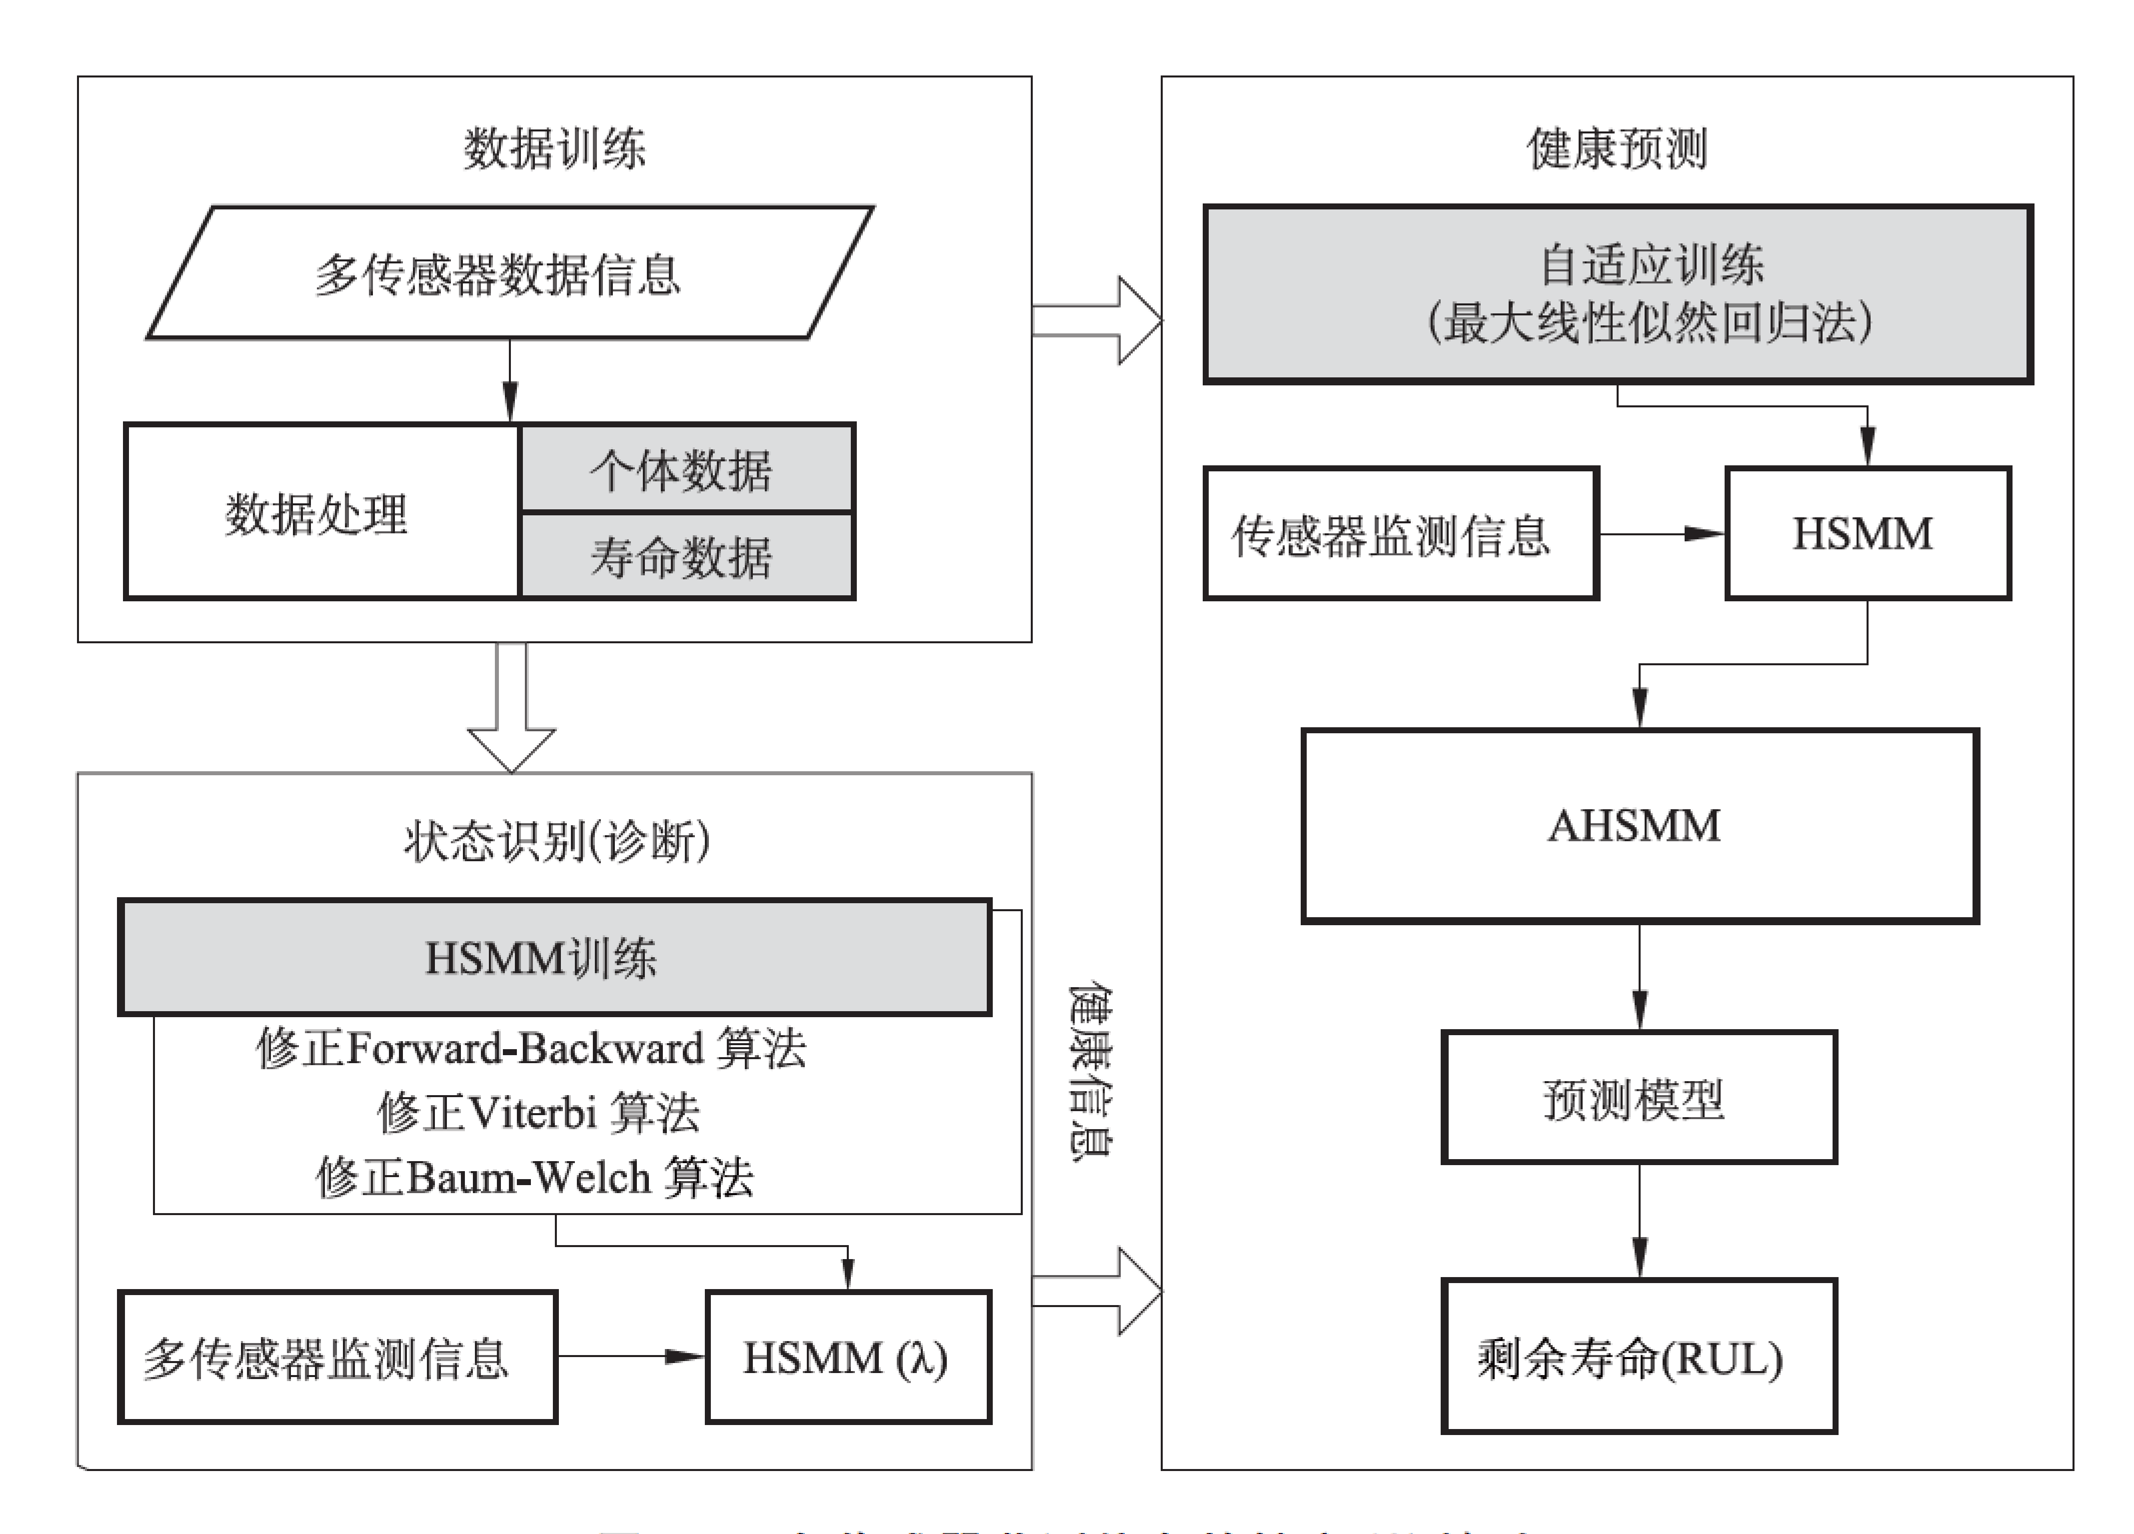


图 4-1 多传感器监测信息的健康预测框架

4.3.3 剩余有效寿命预测方法

在实际应用领域中,失效率(hazard rate,HR)和有效剩余寿命(residual useful life,RUL)函数在很多学科的研究中都会涉及[73,120],监测数据的多种特性都可以通过它们来体现。

在设备的寿命分析过程中,HR 是一个重要指标。HR 的主要内容包括以下几点。

(1) 设备的可靠度函数。可靠度是指一定的条件下和一定的时间内,设备能正常工作的概率。设备的可靠度是与时间相互关联的,在较短的时间内,设备的可靠度可能会增大,在较长的时间内,可能会减少。用 $R(t)$ 来表示设备的可靠度函数。

$$R(t) = P(t < T), P \in [0,1]$$

t 表示设备在运转中的时刻点,T 代表了整个设备的寿命。$R(t)$ 表示了在 $[0,t]$ 时间段内设备进行正常工作的概率[$R(0) = 1, R(\infty) = 0$]。

(2) 设备寿命的分布函数。在一定的时间内和一定的条件下,设备发生失效

的概率，称为设备寿命的分布函数。用 $F(t)$ 表示设备寿命的分布函数，则 $F(t)+R(t)=1$，$[F(0)=0, F(\infty)=1]$。

(3) 设备失效概率的密度函数。当 $t=0$ 时，$F(0)=0$，并且，$f(t)=F'(t)$ 存在，则，我们称 $f(t)$ 为设备失效概率的密度函数。$f(t)$ 主要说明了在单位时间的时刻点上，设备发生失效的概率。

(4) 设备的 HR 函数。到时刻 t 为止，还没有失效的设备在时刻 t 之后的单位时间内发生失效的概率，称为 HR 函数。用 $\lambda(t)$ 表示 HR 函数。

$$\lambda(t)=\lim_{\substack{N\to\infty\\ \Delta t\to 0}}\frac{\Delta k(t)}{[N-k(t)]\Delta t}=\frac{\mathrm{d}k(t)}{[N-k(t)]\mathrm{d}t}=\frac{\mathrm{d}k(t)/M}{1-F(t)}=f(t)/R(t)$$

N 表示监测样本总数量，$k(t)$ 为在时刻 t 之前发生失效的样本总数量。在时间间隔 $(t, t+\Delta t)$ 中，失效的样本数量用 $\Delta k(t)$ 表示[117]。

(5) 设备的 RUL 函数。当设备处于时刻 t 时，到设备失效时刻之间的期望值，称为设备的 RUL，用 $m(t)$ 来表示。

$$m(t)=E(T-t \mid T>t)=(1/R(t))\int_{o}^{\infty}R(x)\mathrm{d}x \quad R(t)>0$$

$\lambda(t)\mathrm{d}t$ 表示设备到 t 时刻时，没有发生失效，但是在时间间隔 $(t, t+\Delta t)$ 发生失效的条件概率[118]。

某台设备在到达其失效状态前，经历过其他的健康状态 $i(i=1,2,\cdots,n-1)$。$D(i)$ 是设备在健康状态 i 的时间驻留长度，基于方程(4-29)和方程(4-30)，$D(i)$可以被描述为

$$D(i)=m(i)+\rho\sigma^2(i)$$

$$\rho=\left(T-\sum_{i=1}^{N}m(i)\right)\bigg/\sum_{i=1}^{N}\sigma^2(i)$$

当设备进入健康状态 i 后，RUL 是设备停留在当前健康状态 i 的剩余时间驻留与后续所有经历的健康状态的驻留时间之和。基本计算结构如图 4-2 所示。

让 $\overline{D}(i,d)$ 表示设备停留在当前健康状态 i 且已经历过的时间驻留为 d 的剩余有效时间驻留。当设备在时间 t 进入健康状态 i 时，在时间间隔$(t+d\Delta t, t+(d+1)\Delta t)$中，失效率的条件概率被定义为在将来的时间 Δt 内设备从健康状态 i 转移到其他任何状态的概率与在时间$(t+\Delta t)$设备仍然停留在当前健康状态 i 的概率的比值。因此，失效率的条件概率表示为

$$\lambda(t+d\Delta t)\Delta t=\frac{(\text{设备在接下的时间 }\Delta t\text{ 中状态转换到任意其他状态的概率})}{(\text{设备在刻}(t+d\Delta t)\text{ 仍旧停留在状态 }i\text{ 的概率})}$$

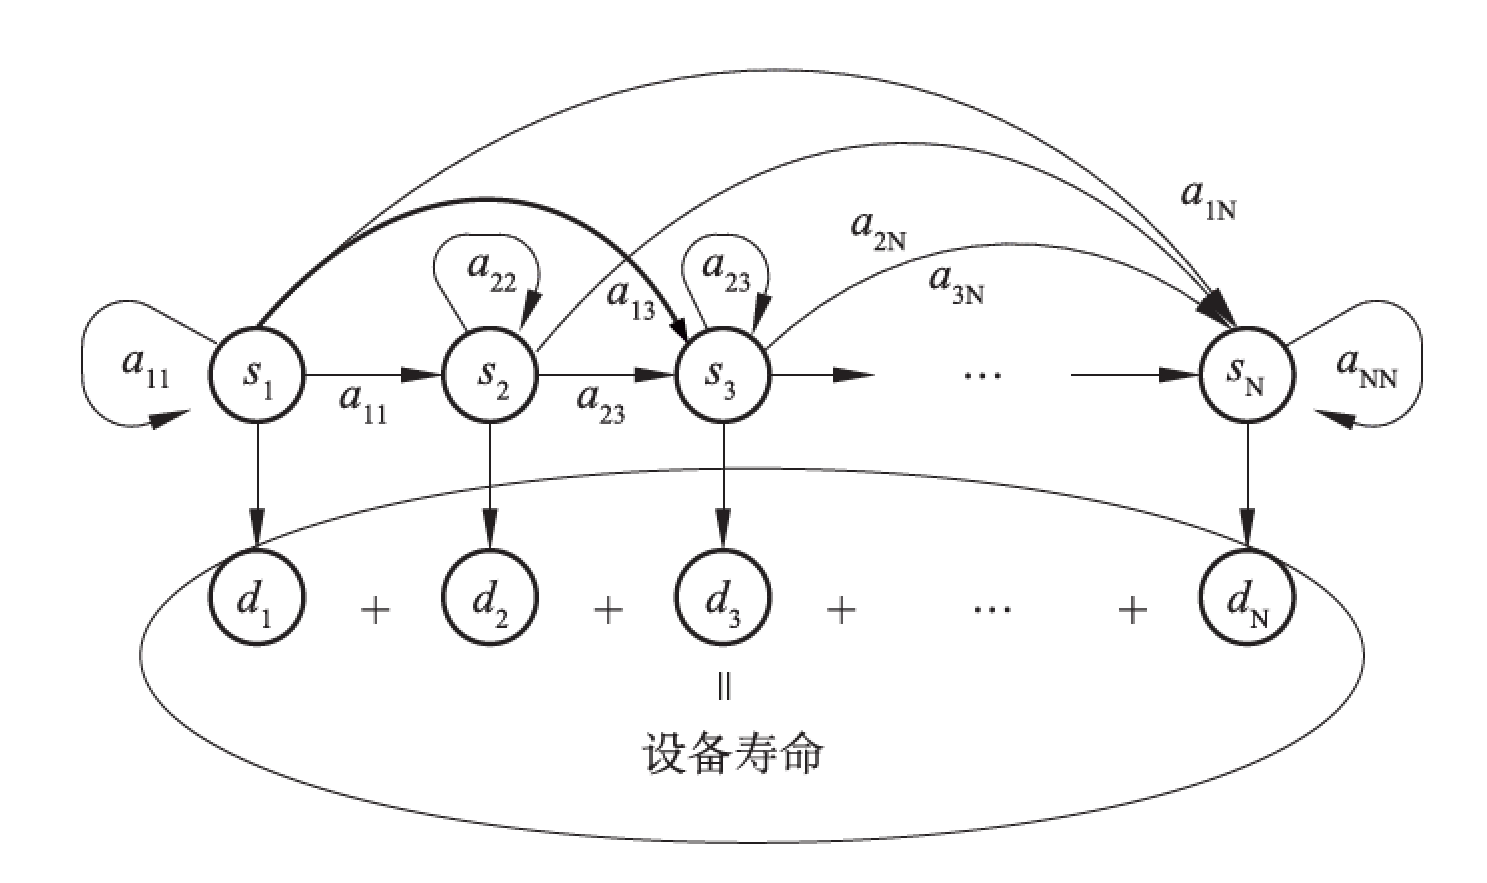


图 4-2 基于具有多传感器信息的寿命框架

这里 d 表示设备进入状态 i 后的已经历时间驻留，满足条件

$$a_{t+\Delta T} = a_{t+2\Delta T} = \cdots = a_{t+d\Delta T} = i$$

设备的可靠度函数 $R(t+d\Delta t)$ 表示了在时刻 $t+d\Delta t$，设备仍然停留在当前健康状态 i 的概率，则

$$R(t+d\Delta t) = \gamma_t^d(i)$$

因此，

$$\bar{\lambda}(t+d\Delta t)\Delta t = \xi_t^d(i,j)/\gamma_t^d(i) \tag{4-34}$$

基于方程(4-33)，$\overline{D}(i,d)$ 表示为

$$\overline{D}(i,d) = D(i)(1-\bar{\lambda}(t+d\Delta t)\Delta t) = D(i)(1-\xi_t^d(i,j)/\gamma_t^d(i)) \tag{4-35}$$

基于方程(4-33)和方程(4-34)，在设备进入状态 i 后，并且已经历的时间驻留为 d 时，对应的有效剩余寿命可以计算如下

$$\mathrm{RUL}_{(i,d)} = \overline{D}(i,d) + \sum_{j=i+1}^{N} D(j) \tag{4-36}$$

本章所提出的方法被用于识别多监测信息的设备健康状态和估计剩余有效寿命。通过与失效率结合的 AHSMM，设备健康预测算法的计算步骤如下。

第一步，基于 AHSMM 的训练算法，获得设备健康状态的初始状态转移概率和健康状态的驻留时间。

第二步，通过 AHSMM 的参数估计，获得每个健康状态的驻留概率密度函数，在此基础上，计算每个健康状态的驻留均值和方差可以。

第三步，基于修正的前后向算法，识别设备的当前健康状态。

第四步，基于方程(4-34)，计算失效率函数。

第五步，基于方程(4-35)，计算设备停留在健康状态 i 且已经历时间驻留为 d 时的期望剩余有效驻留。

第六步，基于方程(4-36)，当设备进入健康状态 i 时，预测在第 d 个观测时刻点的设备剩余有效寿命 RUL。

4.4 算例分析

以第三章的液压泵(设备)为研究对象，对本章内容进行分析。利用多传感器监测信息，进行设备的多监测信息在线健康预测，在案例分析中，将预测结果与设备的实际结果相比较。对提出的方法进行分析，说明提出方法在多监测信息在线健康预测方面的有效性。数据分析平台为 VC，运行环境为 Windows XP。

对于本章的多监测信息，除了第三章中的液压泵的振动信息外，还包括液压泵的温度信息、油膜信息和压力信息。采用液压泵总计 42 组数据来描述液压泵的全寿命过程。42 组原始监测数据的 RMS 描述液压泵的状态变化趋势如图 4-3 所示。从图 4-3 中可以看出，在初始监测阶段，RMS 显示了稳定的操作阶段。随着状态的不断发展，有一些强的变化阶段随观察时间点的增长，包括在第 11 个观察时间点有一个强的变化阶段，在第 21 个观测时间点有一个强的变化阶段，在第 31 个观察时间点有一个强的变化阶段。这些点可以被描述为状态转移点。因此，基于这些状态转折点，液压泵可分为四种状态，包括好(Baseline)、中(Degradation 1)、差(Degradation 2)、坏(Failure)。

4.4.1 数据准备

对于案例中液压泵的健康预测分析，来自 4 个传感器的监测数据被用来预测设备的健康。一个具有 4 个健康状态的 AHSMM 被训练，其中，对于 4 个健康状态之间的状态转移概率，则是液压泵初始运转过程中的转移概率，对于每个健康状态的驻留时间的期望值，也可以经过 HSMM 的训练得到。对于健康状态转移概率和健康状态的驻留时间期望值分别如表 4-1 和表 4-2 所示。

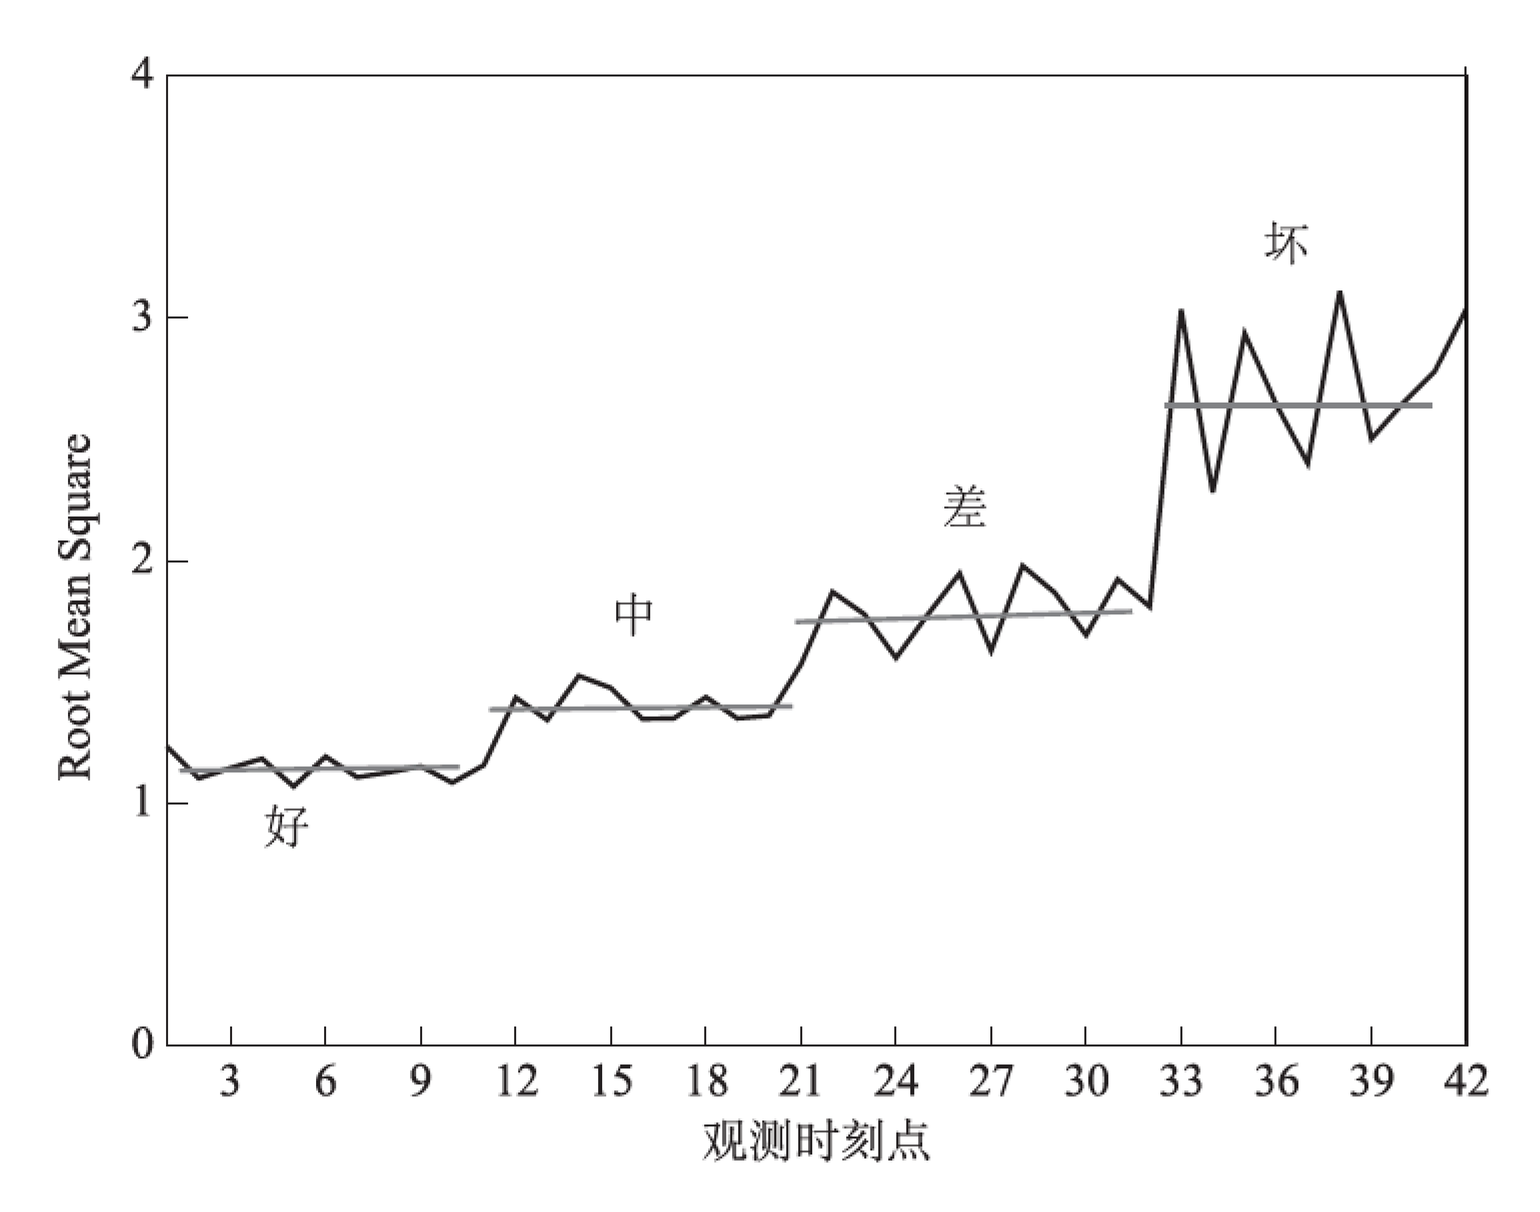


图 4-3　监测数据的变化趋势

表 4-1　健康状态间的原始转移概率

健康状态	好	中	差	坏
好	0.890 3	0.108 9	0.000 6	0.000 2
中	0	0.719 4	0.280 2	0.000 4
差	0	0	0.981 6	0.018 4
坏	0	0	0	1

表 4-2　健康状态期望驻留时间

健康状态	好	中	差	坏
驻留均值	10.635 1	9.675 3	11.543 2	—
驻留方差	1.929 1	1.058 1	1.284 1	—
$D(h_i)$	10.700 9	9.713 3	11.585 8	—

在本案例中，对于每一健康状态观测时刻点，液压泵的历史健康状态趋势如图 4-4 所示，其中，对于坐标轴 y，1 表示好，2 表示中，3 表示差，4 表示坏。从图 4-4 中可以看出，液压泵的健康状态随着时间的变化，呈衰退趋势。

4.4.2　在线健康状态识别分析

基于训练后的 AHSMM，不同操作条件下的实验数据被用于验证提出的状态

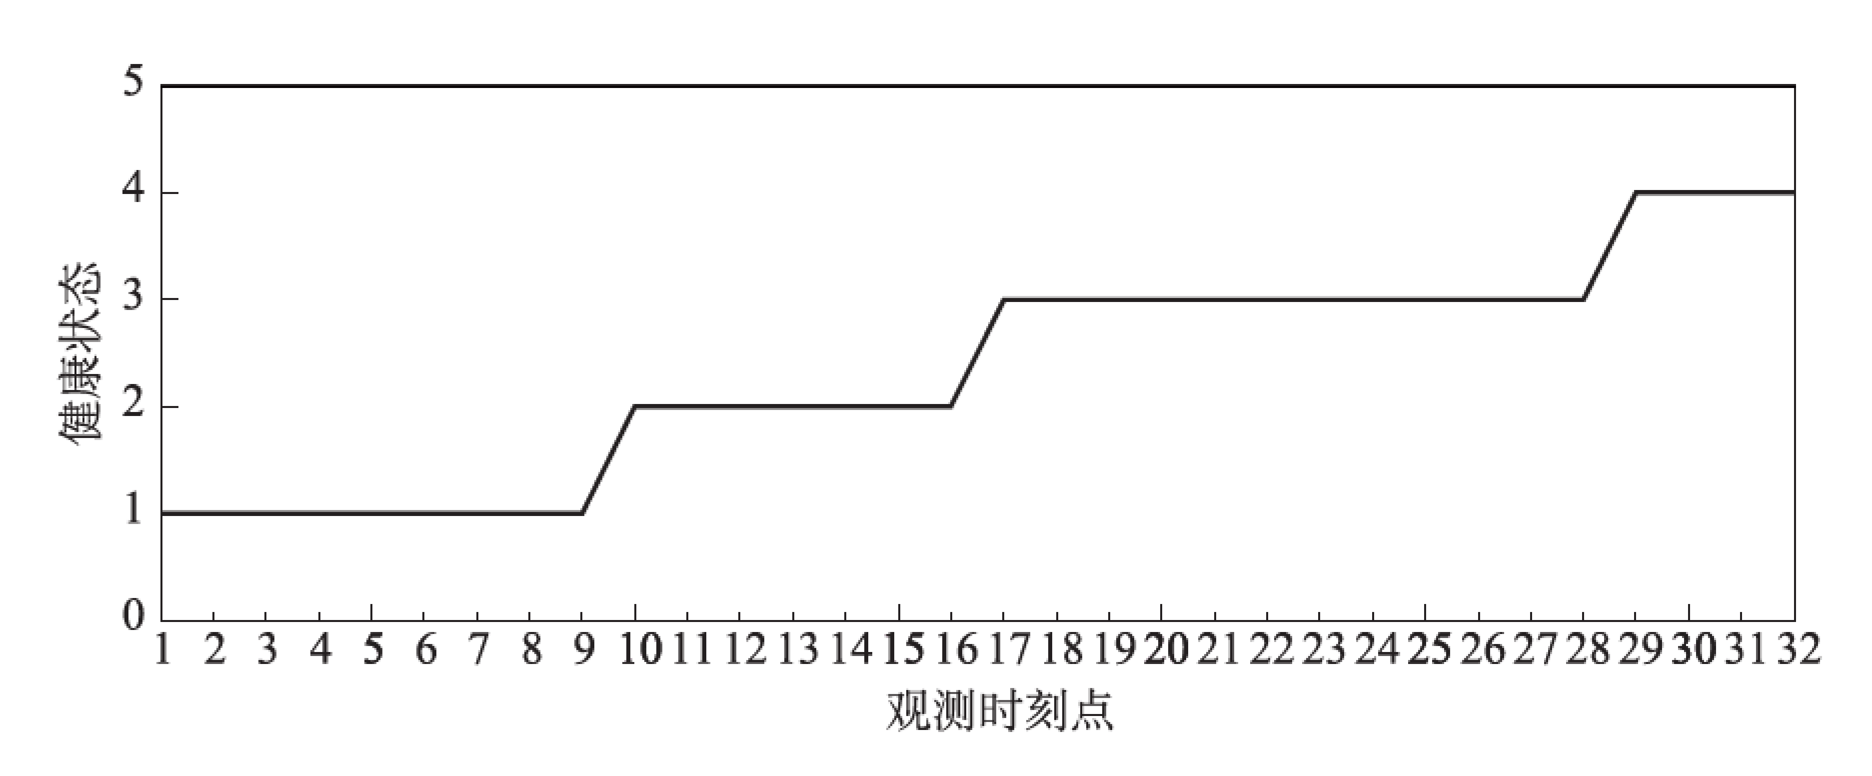


图 4-4 原始健康数据的状态演化

识别方法的精确度。每一个健康状态包含 10 个实验数据的样本，以验证 AHSMM 的有效性。

在 AHSMM 中，可以获得 4 个健康状态的输出概率和状态驻留概率，在模型训练过程中，程序中设置训练的最大迭代步数为 45，收敛误差限定在 $e=0.000\ 001$，对液压泵进行 AHSMM 训练时，一般经过 20 步左右的迭代过程都能收敛。

基于 AHSMM，液压泵的四种健康状态 AHSMM 训练曲线如图 4-5 所示。其中 x 轴代表了训练步数，y 轴代表了不同健康状态的似然概率。基于图 4-5，随着模型迭代次数不断增加，对于设备每个健康状态的似然概率对数值，它们都是逐渐收敛的。这说明了 AHSMM 具有快速学习能力和强的实时信号处理能力。

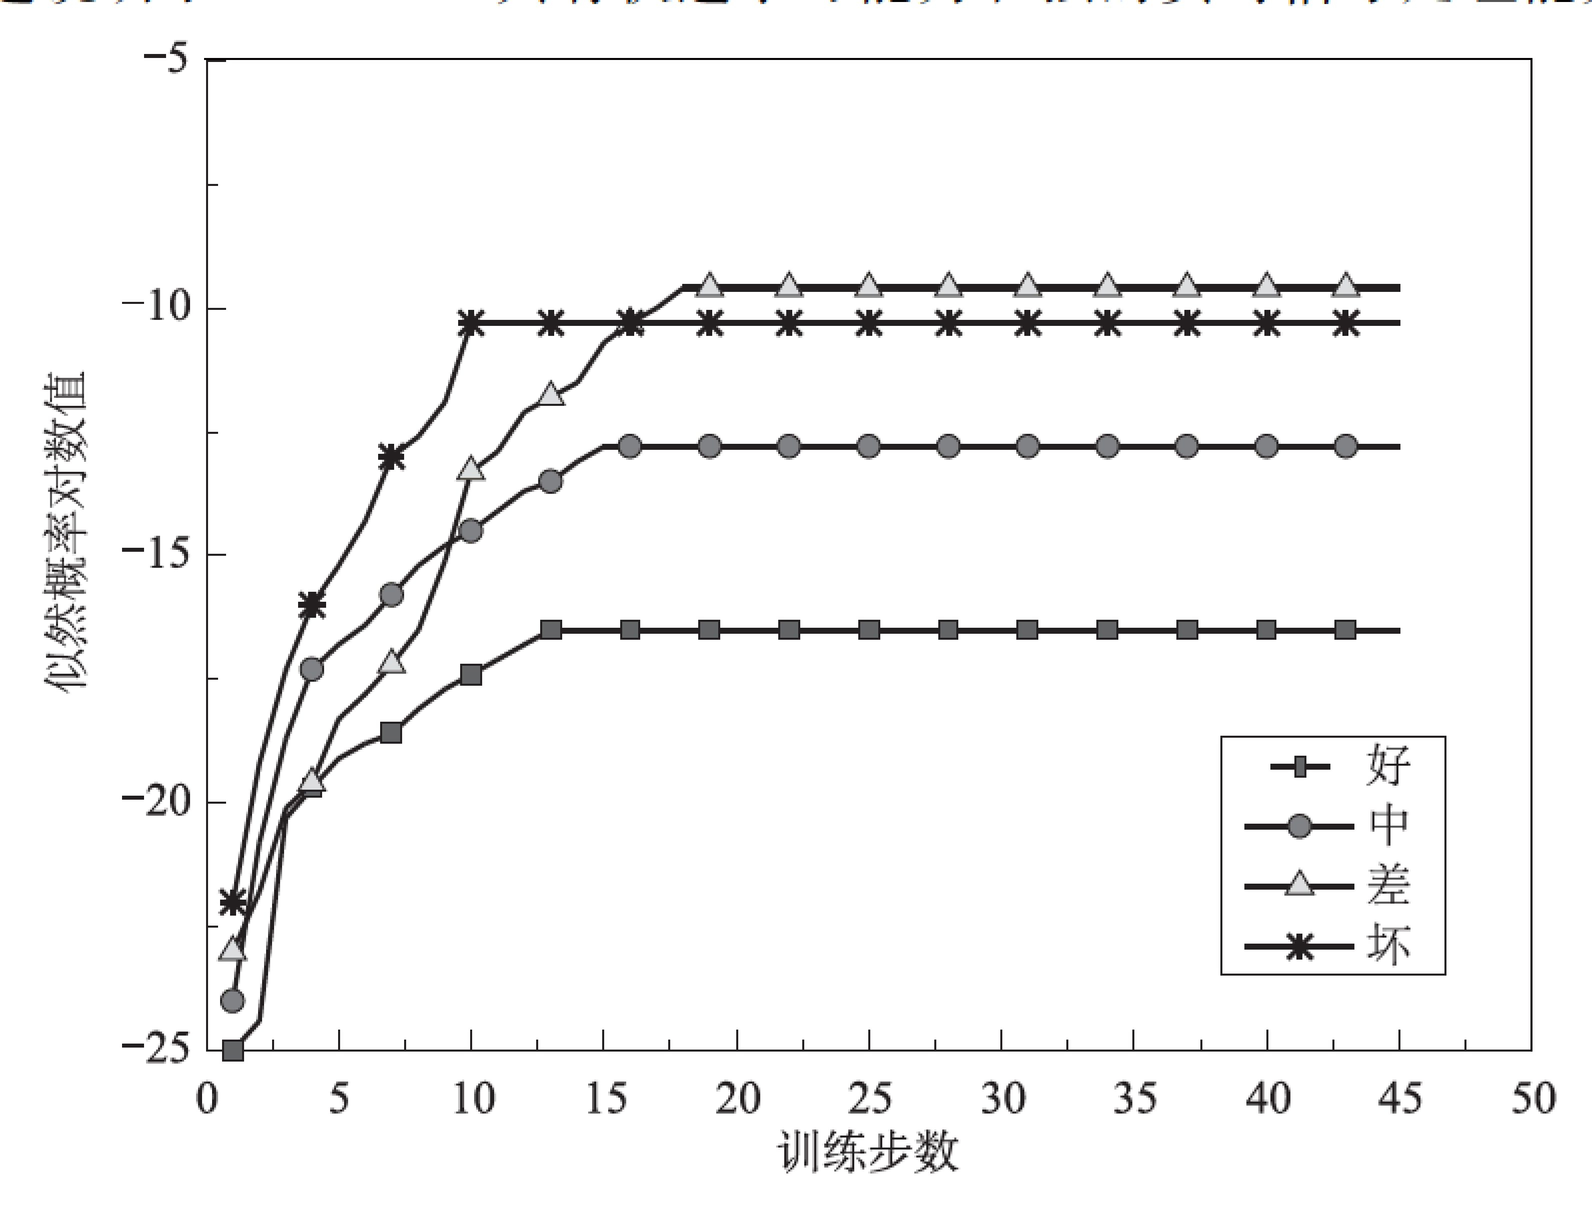
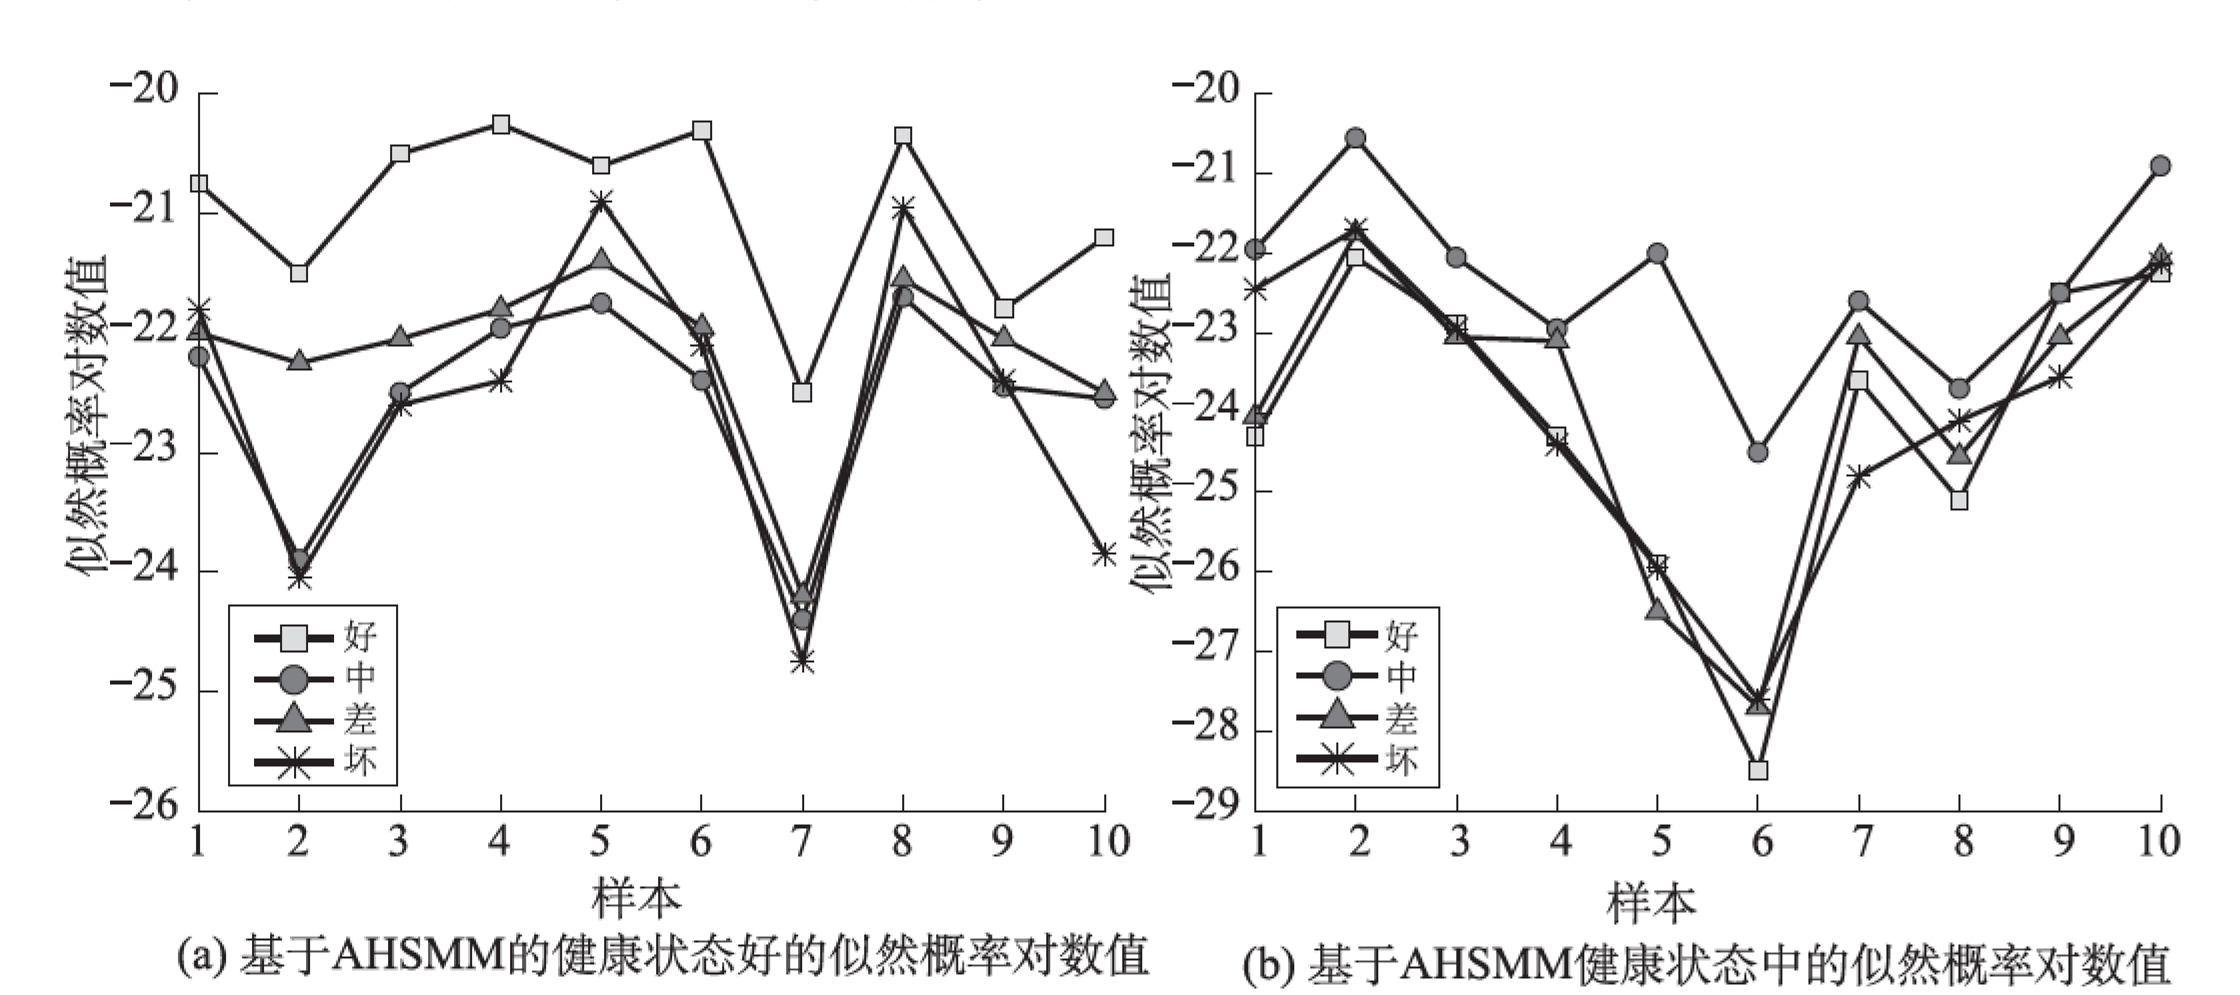
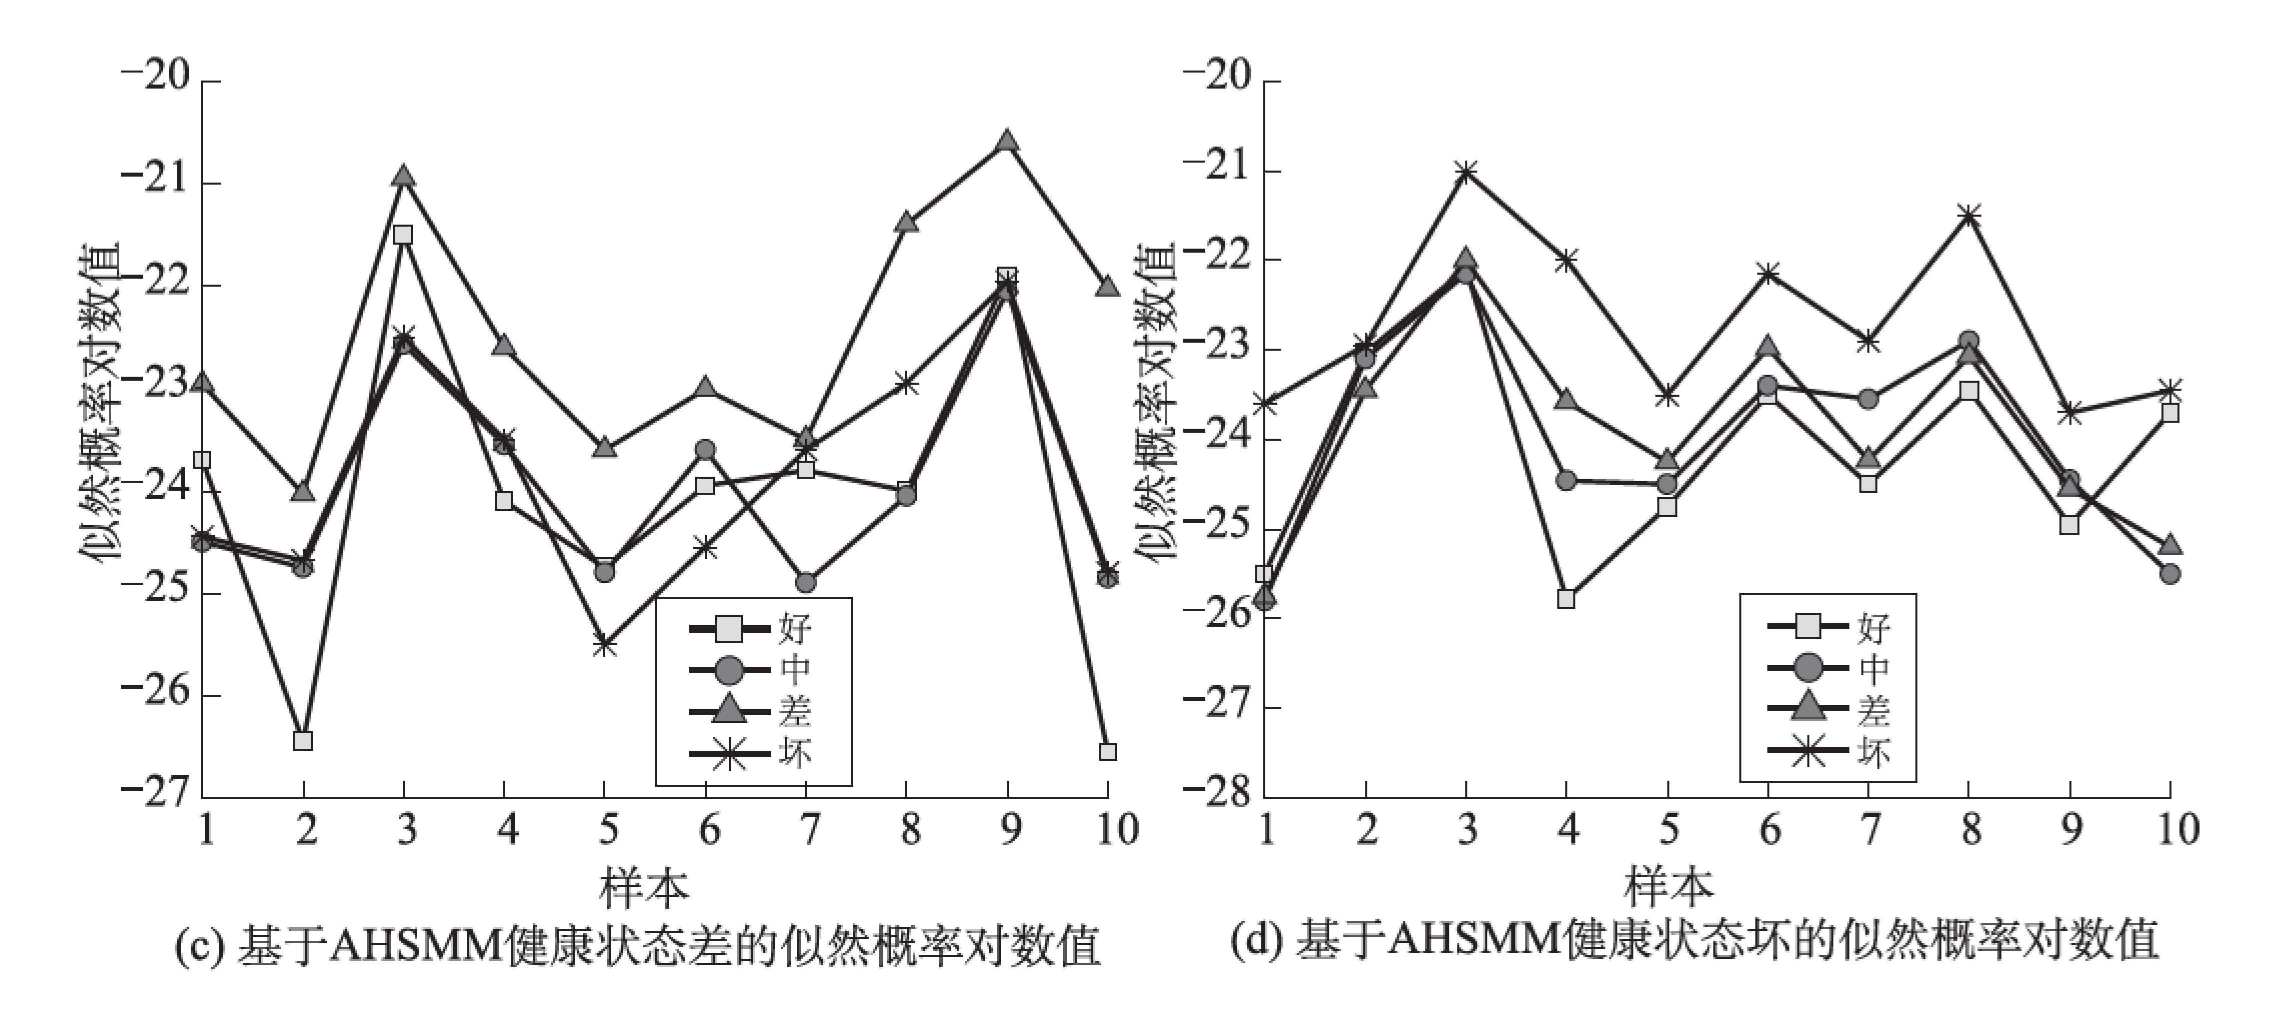


图 4-5 四种状态的 AHSMM 训练曲线

基于方程(4-33),在完成设备健康状态的 AHSMM 的训练后,可以得到液压泵每个健康状态的似然概率值,从而,AHSMM 的健康状态识别的模型库被获得。通过利用本章中的修正 Viterbi 算法,获得液压泵健康状态的特征向量序列在 AHSMM 健康状态识别模型库中每个识别模型下所输出的似然概率对数值。每个健康状态的最大输出概率作为该状态的故障类型。对于每个健康状态的观测样本在分类器中输出的似然概率对数值如图 4-6 所示。



(a) 基于AHSMM的健康状态好的似然概率对数值
(b) 基于AHSMM健康状态中的似然概率对数值



(c) 基于AHSMM健康状态差的似然概率对数值
(d) 基于AHSMM健康状态坏的似然概率对数值

图 4-6　不同健康状态的似然概率对数值比较

基于图 4-6,可以获得 40 个数据样本的状态识别结果,具体的分类结果如表 4-3所示。同时,来自传感器 1 的分类结果和传感器 3 的分类结果也如表 4-3 所

示。从表 4-3 中看出，AHSMM 的识别精度是 100%，也就是说，自适应训练很好地融合了多个传感器的信息，即对于具有多传感器信息的设备健康识别，AHSMM 是非常有效的。在下一节中，将进一步讨论 AHSMM 的健康预测功能。

表 4-3 健康状态识别结果

健康状态		好	中	差	坏	识别精度(%)
AHSMM	好	10	0	0	0	100
	中	0	10	0	0	100
	差	0	0	10	0	100
	坏	0	0	0	10	100
	总精度	100%				
基于 Sensor 1 的 HSMM	好	9	1	0	0	90
	中	0	9	1	0	90
	差	0	1	9	0	90
	坏	0	0	1	9	90
	总精度	90.00%				
基于 Sensor 3 的 HSMM	好	9	1	0	0	90
	中	1	9	0	0	90
	差	0	0	9	1	90
	坏	0	1	1	8	80
	总精度	87.50%				

4.4.3 在线健康预测分析

基于 4.3 节，建立了四个健康状态的 AHSMM 的预测模型，为了测试提出的健康预测方法，首先，在液压泵进入健康状态"好"后，6 个观测时刻点被用于计算液压泵的 RUL 和测试 AHSMM 的性能。在液压泵进入健康状态 Baseline 后，按照下列计算步骤来计算这 6 个观测时刻点的 RUL。

第一步，基于方程(4-34)，计算从第 1 个时刻点到第 6 个时刻点的 $\bar{\lambda}(t+d\Delta t)\Delta t$，计算结果如下所示：

$$\bar{\lambda}(t+1\Delta t)\Delta t = 0.1074,\ \bar{\lambda}(t+2\Delta t)\Delta t = 0.1372,\ \bar{\lambda}(t+3\Delta t)\Delta t = 0.1835,$$

$$\bar{\lambda}(t+4\Delta t)\Delta t = 0.2194,\ \bar{\lambda}(t+5\Delta t)\Delta t = 0.3279,\ \bar{\lambda}(t+6\Delta t)\Delta t = 0.4582$$

第二步，计算液压泵停留在状态 Baseline 的期望剩余驻留时间 $\bar{D}(i,d)$，计算结果如下所示：

$$\bar{D}(1,1)=D(1)(1-\bar{\lambda}(t+1\Delta t)\Delta t)=10.6739\times(1-0.1074)=9.5275$$
$$\bar{D}(1,2)=D(1)(1-\bar{\lambda}(t+2\Delta t)\Delta t)=10.6739\times(1-0.1372)=9.2094$$
$$\bar{D}(1,3)=D(1)(1-\bar{\lambda}(t+3\Delta t)\Delta t)=10.6739\times(1-0.1835)=8.7152$$
$$\bar{D}(1,4)=D(1)(1-\bar{\lambda}(t+4\Delta t)\Delta t)=10.6739\times(1-0.2194)=8.3320$$
$$\bar{D}(1,5)=D(1)(1-\bar{\lambda}(t+5\Delta t)\Delta t)=10.6739\times(1-0.3279)=7.1739$$
$$\bar{D}(1,6)=D(1)(1-\bar{\lambda}(t+6\Delta t)\Delta t)=10.6739\times(1-0.4582)=5.7831$$

第三步，计算 $RUL_{(i,d)}$ ，计算结果如下所示

$$\text{RUL}_{(1,1)}=\bar{D}(1,1)+\sum_{j=2}^{4}D(j)=9.5275+9.8437+11.5468=30.9180$$
$$\text{RUL}_{(1,2)}=\bar{D}(1,2)+\sum_{j=2}^{4}D(j)=9.2094+9.8437+11.5468=30.5999$$
$$\text{RUL}_{(1,3)}=\bar{D}(1,3)+\sum_{j=2}^{4}D(j)=8.7152+9.8437+11.5468=30.1057$$
$$\text{RUL}_{(1,4)}=\bar{D}(1,4)+\sum_{j=2}^{4}D(j)=8.3320+9.8437+11.5468=29.7225$$
$$\text{RUL}_{(1,5)}=\bar{D}(1,5)+\sum_{j=2}^{4}D(j)=7.1739+9.8437+11.5468=28.5644$$
$$\text{RUL}_{(1,6)}=\bar{D}(1,6)+\sum_{j=2}^{4}D(j)=5.7831+9.8437+11.5468=27.1736$$

然后，为了显示预测 RUL 和实际 RUL 之间的关系，选取 6 个观测时刻点进行两者比较，如表 4-4 所示。从表 4-4 中可以看到，所提出的健康预测方法对于多传感器的液压泵健康预测是非常有效的。其中，相对误差根据以下公式获得。

相对误差＝100%×|实际 RUL－预测 RUL|/实际 RUL

表 4-4　预测 RUL 和实际 RUL 比较结果(6 个观测时刻点)

实际 RUL	预测 RUL	相对误差(%)
32.000 0	30.918 0	3.381 2
31.000 0	30.599 9	1.290 5
30.000 0	30.105 7	0.352 5
29.000 0	29.722 5	2.491 5
28.000 0	28.564 4	2.015 8
27.000 0	27.173 6	0.643 0

为了进一步说明提出的健康预测方法对多传感器信息的液压泵在线健康预测有一个更好的性能,从 6 个观测时刻点扩展到 29 个观测时刻点来说明这个模型的性能。因此,基于方程(4-35)和方程(4-36),计算 29 个观测时刻点的 RUL 值,同时,预测的 RUL 和实际 RUL 如表 4-5 所示。预测的 RUL 和实际 RUL 之间的比较结果也如图 4-7 所示。基于表 4-5 和图 4-7,可以看出预测的 RUL 和实际 RUL 之间的相对误差是非常小的。这说明了液压泵的剩余有效寿命通过提出的方法可以很好的获得,预测的设备健康状态很好地匹配了设备的实际状态。

表 4-5 预测 RUL 和实际 RUL 比较结果(29 个观测时刻点)

实际 RUL	预测 RUL	相对误差(%)	实际 RUL	预测 RUL	相对误差(%)
32.000 0	30.918 0	3.381 2	17.000 0	17.683 1	4.018 2
31.000 0	30.599 9	1.290 5	16.000 0	17.254 7	7.841 9
30.000 0	30.105 7	0.352 5	15.000 0	13.869 4	7.537 3
29.000 0	29.722 5	2.491 5	14.000 0	13.613 8	2.758 6
28.000 0	28.564 4	2.015 8	13.000 0	13.547 3	4.210 0
27.000 0	27.173 6	0.643 0	12.000 0	13.262 5	10.520 8
26.000 0	25.632 7	1.412 7	11.000 0	12.816 4	16.512 7
25.000 0	24.338 2	2.647 2	10.000 0	9.857 9	1.421 0
24.000 0	23.583 9	1.733 8	9.000 0	9.807 3	8.970 0
23.000 0	23.371 8	1.616 5	8.000 0	9.271 8	15.897 5
22.000 0	22.195 2	0.887	7.000 0	8.138 2	16.260 0
21.000 0	22.656 9	7.890 0	6.000 0	7.586 2	26.436 7
20.000 0	21.178 3	5.891 5	5.000 0	5.809 3	16.186
19.000 0	18.694 3	1.608 9	4.000 0	5.413 7	35.342 5
18.000 0	18.157 6	0.875 6			

4.4.4 预测性能评估

通过本章提出的健康预测方法,可以很好地预测多传感器信息的设备健康。同时,为了说明 AHSMM 对于多传感器信息的设备健康预测有很好的性能,HSMM 方法也被用于预测多传感器信息的液压泵的健康,并且与 AHSMM 及单监测信息的健康预测进行了性能比较。预测结果如表 4-6 所示,并且,对应的比较结果如图 4-8 所示。从表 4-6 和图 4-8 中可以看出,与 HSMM 相比,在处理多传感

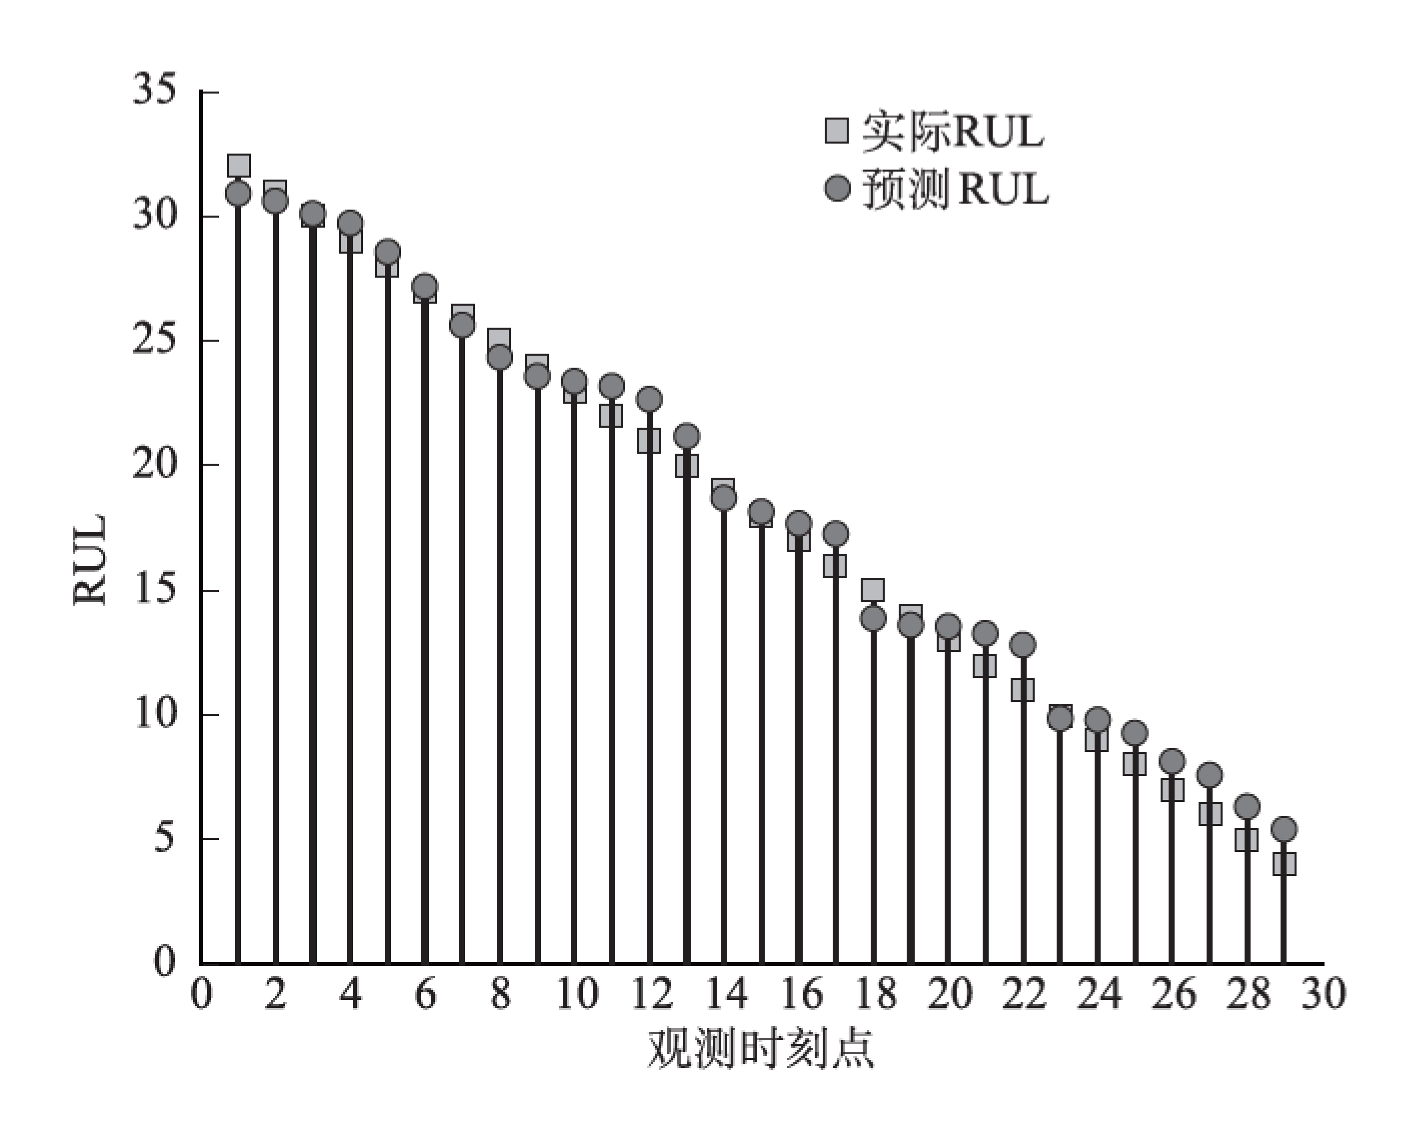


图 4-7 基于 AHSMM 的预测 RUL 和实际 RUL 比较结果

器信息的健康预测方面，AHSMM 具有更好的预测性能，并且，多监测信息的健康预测精度优于单监测信息的健康预测精度。

表 4-6 三种方法的预测结果

实际 RUL	AHSMM		单监测信息预测模型		HSMM	
	预测 RUL	相对误差(%)	预测 RUL	相对误差(%)	预测 RUL	相对误差(%)
30	30.105 7	0.352 5	29.398	2.006 7	30.255 8	0.852 7
26	25.632 7	1.412 7	25.214 2	3.022 3	29.964 3	15.247 3
22	22.195 2	0.887	22.517 2	2.350 9	29.795 4	35.433 6
17	17.683 1	4.018 2	17.513 4	3.02	19.498 1	14.694 7
15	13.869 4	7.537 3	16.077 6	7.184	19.208 1	28.054
12	13.262 5	10.520 8	13.162 5	9.687 5	18.866 6	57.221 7
11	12.816 4	16.512 7	12.966 7	17.879 1	10.247 1	6.844 5
9	9.807 3	8.97	9.786 6	8.74	10.029 1	11.434 4
5	5.809 3	16.186	6.055 8	21.116	9.767 5	95.35

基于这五种误差标准，单监测信息健康预测方法、HSMM 和 AHSMM 的性能评估结果如表 4-7 所示。并且，五种误差比较的结果如图 4-9 所示。从表 4-7 和图 4-9 的三种方法的绝对误差和相对误差可以看出，对于处理多传感器信息的设

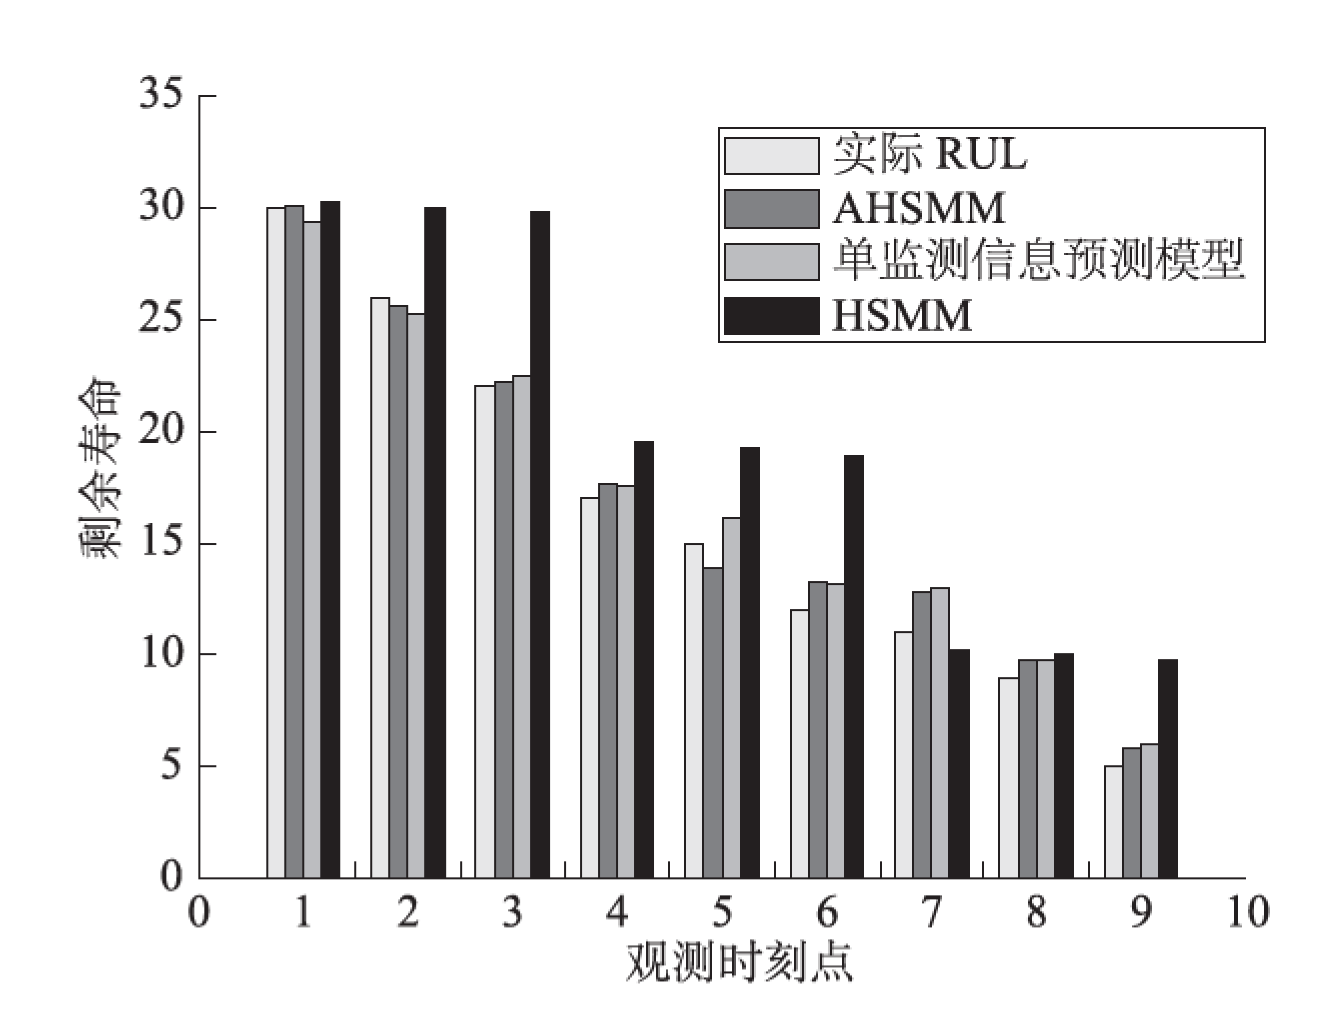


图 4-8　三种方法预测的比较结果

备健康预测，AHSMM 明显优于单监测信息的健康预测模型和 HSMM。

表 4-7　三种方法的性能评估结果

方法	误差				
	RSME	MAE	VAE	MARE	VRE
AHSMM	0.950 4	0.797 5	0.167 2	0.073 8	0.003 4
单监测信息预测模型	1.034 1	0.940 8	0.184 3	0.083 3	0.004 3
HSMM	4.371 7	3.570 9	6.360 4	0.294 6	0.080 3

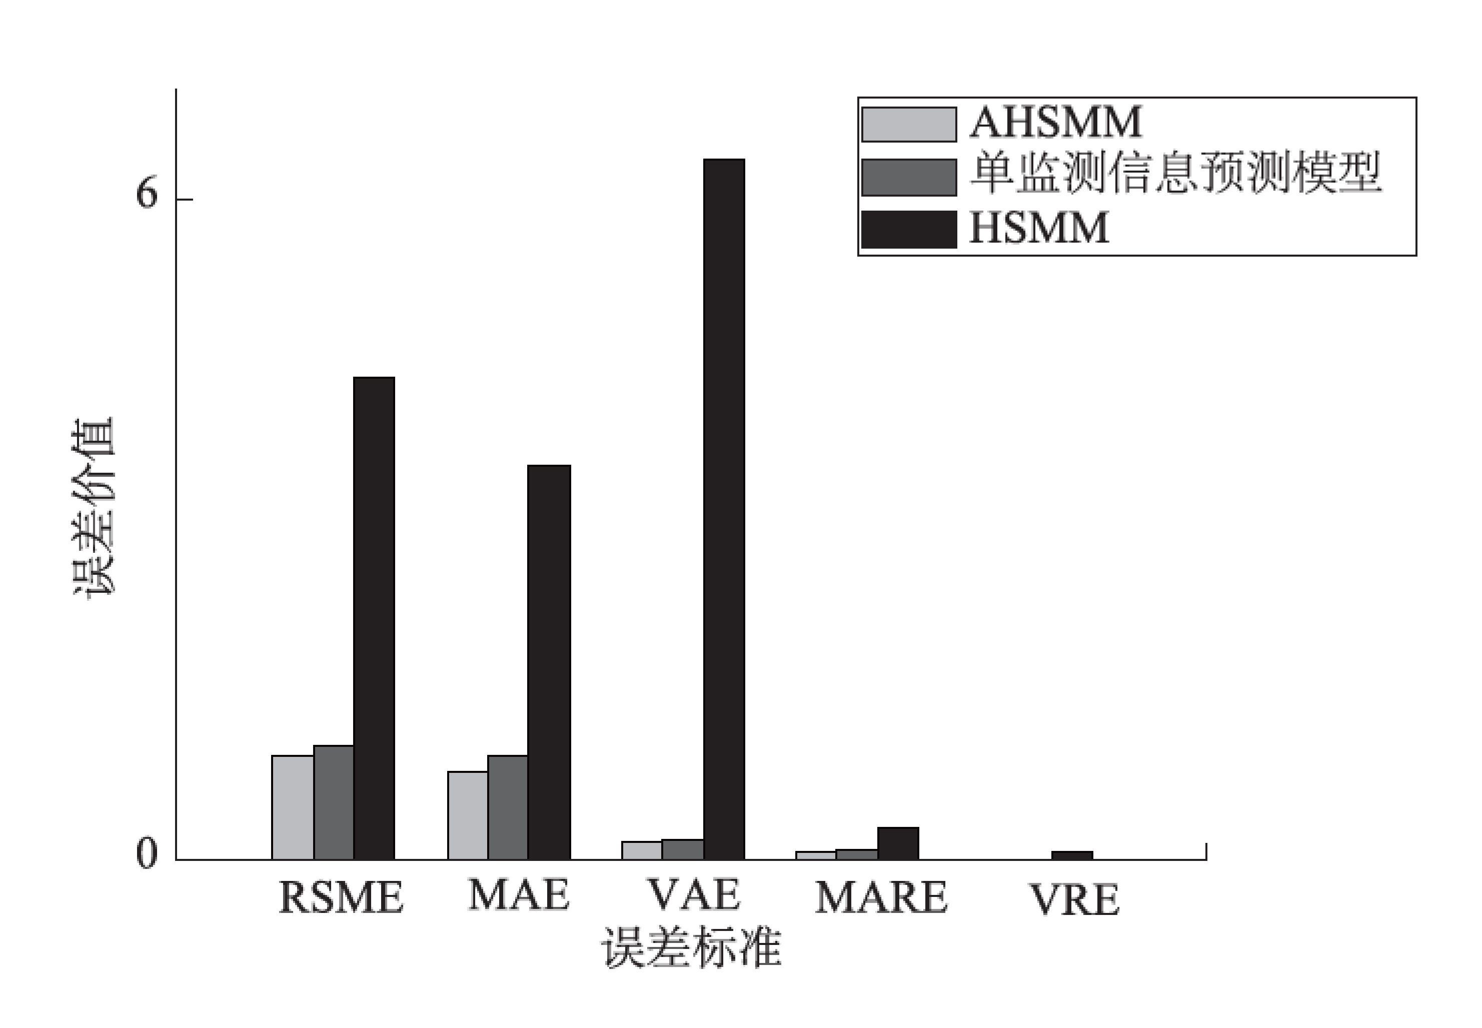


图 4-9　三种方法的误差比较结构

通过对整个算例的分析，基于 AHSMM，利用多监测数据信息，很好地对设备

健康进行了预测。并且,结果显示,在处理多传感器信息的设备健康预测方面,与HSMM相比,AHSMM具有更好的预测性能,包括预测的有效性和预测的准确性。对于单监测信息健康预测,多监测信息的健康预测具有更高的准确性。而且,通过修正HSMM的基本算法,与HSMM相比,AHSMM还降低了模型的计算复杂性。这说明在多监测信息的设备在线健康预测领域,AHSMM是非常有效的,并且,因为AHSMM降低了模型的计算复杂性,AHSMM还可以被用在实时环境下,大数据的多监测信息的在线健康预测。

4.5 本章小结

设备在线健康有效预测是进行维护的前提条件,对设备的健康进行合理有效的分析与建模,有助于为维护提供有效的设备健康信息,包括设备的诊断信息和设备的预测信息,从而实现设备的有效维护,降低设备的维护成本和提高企业生产率。基于第二章的单监测信息在线健康预测方法,本章建立了多监测信息的在线健康预测方法。首先,对在线HSMM进行修正,提出了具有较低计算复杂性的HSMM基本算法,包括修正前向—后向算法、修正的Vitebi算法和修正的BW算法。其次,对修正后的HSMM进行自适应训练,提出了自适应HSMM,它可以有效地融合多传感器的监测信息,从而可以有效地处理多监测的设备在线健康预测。最后,提出了基于失效率的在线设备剩余寿命预测算法。通过案例分析可知,在多监测信息的设备在线健康预测领域,AHSMM与单监测信息的在线健康预测模型进行了比较分析,在设备健康状态识别、设备诊断、剩余寿命预测和计算复杂性方面,AHSMM具有比单监测信息在线健康预测方法更好的性能,因此,可以验证AHSMM在多监测信息的在线健康预测方面是非常有效的。



第 5 章 基于在线健康预测的集成动态维护研究

5.1 引　言

第 4 章讨论了基于 AHSMM 的多监测信息设备在线健康预测问题，本章将在此基础上，研究一种基于设备在线健康预测的集成动态维护问题。这种维护方式将在现实生产企业中得到非常广泛关注与应用。

设备维护策略优化研究始于 20 世纪 50 年代，是维护科学的重要领域之一，也是目前的研究热点问题，在理论和应用上取得大量研究成果。维护优化模型是利用数学工具建立的优化维护策略的计算模型。目前，维护优化的研究对象涉及维护备件的管理、维护策略的优化与选择、维护评价、维护管理战略等；使用的技术方法也很多，如 ANN 法、运筹学、贝叶斯决策分析、随机过程、应用数学等理论。为了提高模型的应用性和可操作性，使用了大量的历史数据和统计数据作为建模的数据来源。维护优化解决的基本问题是何时对系统进行维护、采用何种方式维护及维护后系统功能如何。维护策略优化模型是以寻找维护成本和维护效果的最优平衡为目标建立的数学模型，合理的维护策略可为企业的设备维护工作带来事半功倍的效果。

设备的维护策略包括维护策略的确定、维护能源的约束、维护动作评价、维护的目标管理等。设备维护模型的主要目标是最小化维护成本和最大化维护效果，合理有效的设备维护策略有助于企业设备利用率的提高、企业生产成本的降低和企业生产效率的提高。设备的维护效果如图 5-1 所示。多年来学术界和工业界都投入了大量精力对设备系统的维护策略进行了深入的研究，针对不同的设备系统及相应的维护需求创建了各类行之有效的维护策略，不少策略在工业界得到了广泛应用。

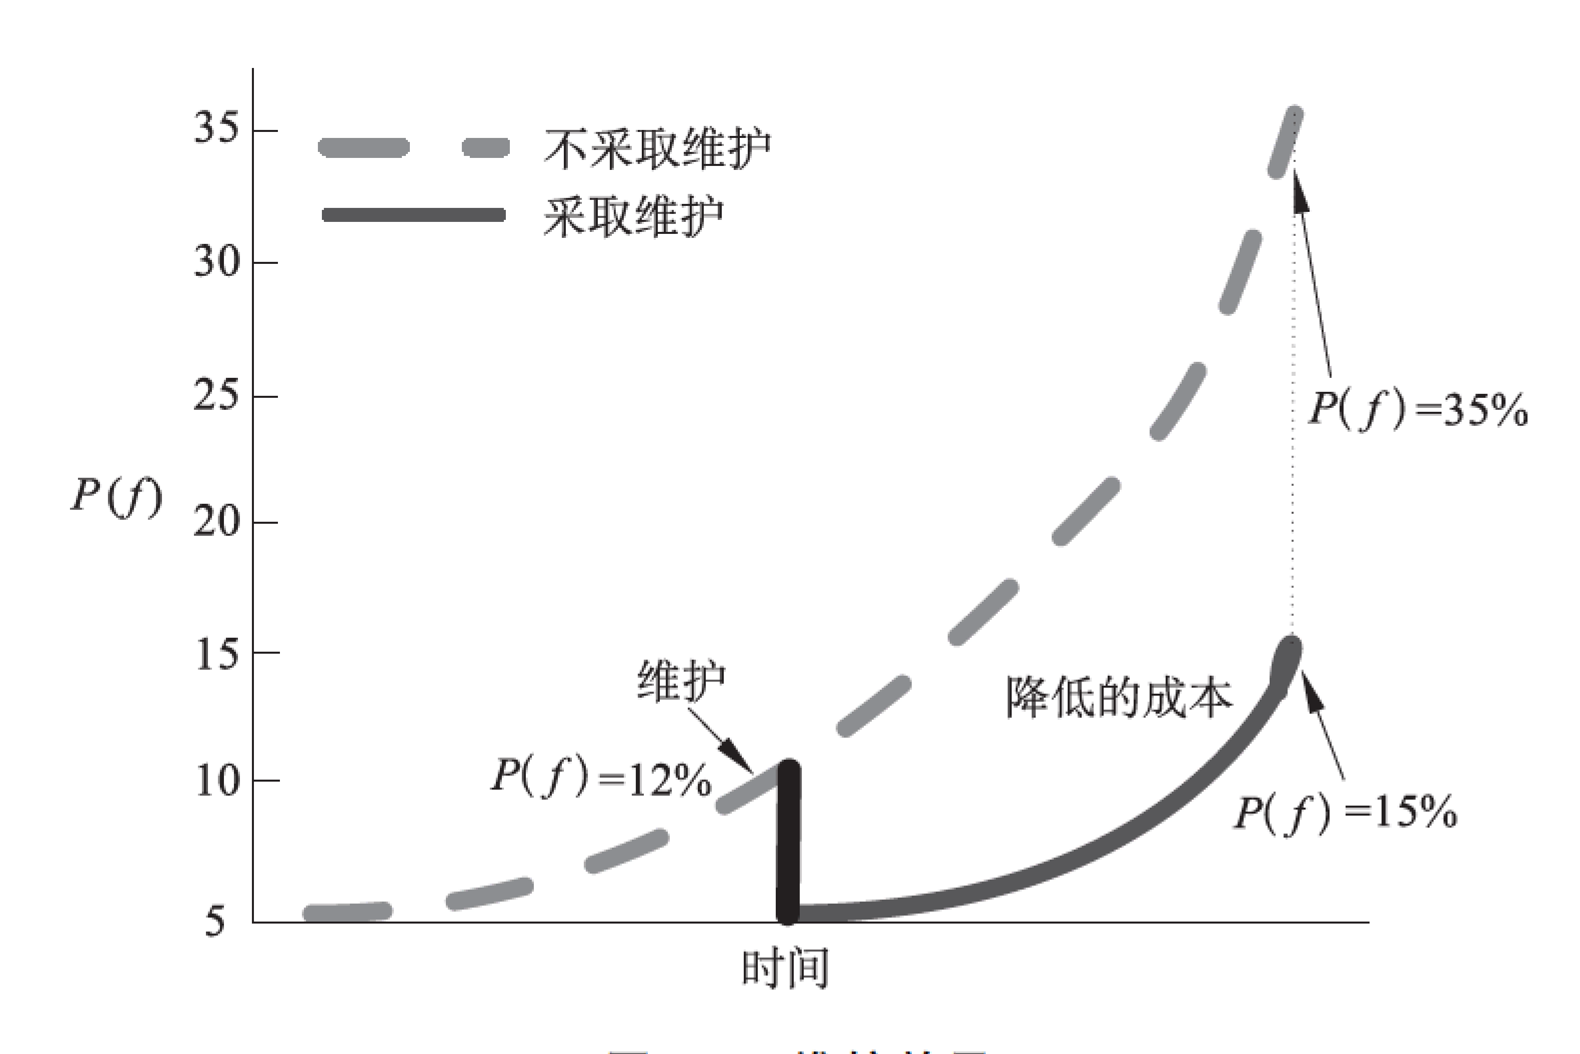


图 5-1　维护效果

维护，又称为维修，是指为了保持或恢复设备系统使其处于正常执行预定功能状态，而进行的所有相关技术和管理活动。通常将维护分为事后维护(corrective maintenance，CM)和预防维护(preventive maintenance，PM)。事后维护是指产品或设备系统故障后使其恢复到规定功能状态所进行的全部活动，也称为修理。预防维护是指通过系统的检查、探测和预防早期故障，使产品或设备系统保持在规定功能状态所进行的全部活动。按照产品或设备系统工作状态的恢复程度，可以将维护分为完全维护(perfect maintenance)、不完全维护(imperfect maintenance)、最小维护(minimal maintenance)、劣化维护(worse maintenance)和最坏维护(worst maintenance)五类。维护的目的是使维护后的设备状态较停机前更好。完全维护是指通过置换或维护使设备恢复至全新状态，不完全维护是指通过维护动作使设备恢复到较佳状态。设备停机后的纠错维修，除完全与不完全维护之外，还可能仅

须恢复运作即可，即进行最小维护，使设备状态恢复至与停机前相同；也可能因为急于恢复运作，而造成了劣化维护，使设备状态反而比停机前略差（因替换二手零件或程序、技术较粗糙）。无论是预防维护或纠错维修，如果维护动作不当或效果不如预期，则实际结果状态可能比目标状态差，因此也可能成为最坏维护，实际结果为设备无法使用。

设备故障对生产活动的影响早在20世纪50年代就引起了人们的注意。文献[234-236]对完备的预防性维护进行了研究，对系统采用周期性检修的方法，假设维护周期不变。但在实际操作中，由于预防性维护并不能使设备修复如新，随着维护次数及系统役龄的增加，周期性维护策略不可避免地会使系统的可靠性逐步降低，而使维护周期中出现故障的次数逐步增加。因此，更符合实际情况的应该是随着设备使用时间的增长，预防性维护的次数随着故障次数的增加逐步增加。文献[237-239]针对非完备的预防性维护进行了研究，分别采用不同的方法来模拟基于改良因子的非完备维护。Nakagawa[240]考虑到实际的可操作性，提出了三种建立于参考时间 t 和维修周期 T 的扩展策略。如果故障在 t 时刻之前发生，则进行小修；如果设备到了周期时间 T 仍在运行，则在 T 时刻进行更新；如果故障出现在 t 和 T 时刻之间，则可以从三种策略中选择执行。

目前，设备的维护策略可以分为以下五类。

（1）基于设备使用寿命的预防性维护策略。基于设备使用寿命的预防性维护策略（age-dependent PM policy）是最常用的维护策略之一，该策略在设备到达它的给定使用寿命时或者失效时进行更换。之后，由于小修和修复非新研究的深入，不少学者对这一策略进行了拓展[241-244]。但是，以上的研究大多都没有具体给出维修/设备更换时间的计算方法，只是简单地假设寿命服从某一分布，如Weibull分布。Amari[244]对设备的使用寿命进行了重点研究，在寿命 T 下，分别给出了设备更换时间的上限和下限。基于设备使用寿命的预防性维护策略一直是维护领域的研究人员的研究热点，也已有了不少研究成果。

（2）周期预防性维护策略。周期预防性维护策略（periodic policy，PM）是指依照固定的时间间隔对设备进行预防性维护。周期预防性维护策略可分为故障小修周期更新策略和块更新策略（block replacement）两类。故障小修周期策略是指设备故障时采用小修的方式解决，达到预设的时间时则更换设备。文献[245]提出的策略是，设备更换只在维护周期 T 时刻时发生，周期期间若发生故障只进行小修。当故障次数大于或等于预先设定的故障次数时，在下一个维护周期时，则应该更换

设备。文献[246]中，设备以固定间隔 T 进行预防性维护，期间出现故障时执行小修动作，当寿命到达预设时间时则更换设备，预设时间与修复非新的次数相关。块更新策略是指设备在预先设定的时间内进行一系列更新。文献[247]的策略是在不考虑设备寿命的情况下，设备在维护周期 T 前发生故障时，不更换设备。文献[248]指出可采用二手设备对故障设备进行更换，当设备寿命大于预先给定的时间时，更换二手设备；否则，更换全新设备。也有不少学者把这两类策略进行合并研究[249-250]。由于周期预防性维护策略具有实施方便、可操作性强等特点，目前仍被众多企业所普遍采用。

（3）不定周期预防性维护策略。与周期预防性维护策略不同，不定周期预防性维护策略中每两次预防性维护的时间间隔是不相等的。通常，随着设备使用年限的增长，预防性维护的时间间隔会逐步缩短，维护周期的时间长度依赖于设备的剩余寿命。在每一次预防性维护之后，只需要确定下一次预防性维护的时间，以求将维护成本降到最低。Nakagawa[251]提出，设备故障率会随着维护次数的增加而增加，寿命也会降低，设备在第 i 次预防性维护时应该更换设备，所有在预防性维护之间发生的故障都采用小修来解决。由于考虑到了设备的预防性维护周期的时间间隔会随着设备使用年限的增长而逐步降低，因而不定周期的预防性维护策略更具可操作性。

（4）失效限制策略。失效限制策略（failure limit policy）是指在失效率或其他可靠性指标达到一个预先设定的阈值时进行预防性维护，让设备在某个可接受的可靠度范围内运行。文献[252]通过对设备状态进行监测的方法，将设备的状态分为持续时间为 T 的正常阶段和持续时间为 W 的退化阶段。预防性维护在 $(T, T+W)$ 之间进行，并且修复如新。如果设备在 $(0, T)$ 之间出现故障，就对设备立即执行修复动作，且修复如新。文献[253]提出了失效限制条件下的维护成本优化策略，预防性维护期间出现的故障均执行小修动作。文献[254-255]都研究了失效限制策略下的状态监测间隔周期的优化工作。文献[256-258]对维护决策的算法模型进行了优化，提高了计算速度，增加了维护模型的实用性。Bergman[259]对失效限制策略进行了总结，并指出设备失效率通常是设备的某些状态变量的函数，如老化程度、累计损坏程度、累计负载等，决策的准则是在保证设备失效率水平的条件下，使设备的维护成本最小化。目前，在这类策略中，仍可以进行许多算法的优化工作。

（5）维修限制策略。维修限制策略（repair limit policy）根据对修复时间和修

复费用的限制分为两类。修复费用限制策略提出于 19 世纪 60 年代[260]，在该策略下，当设备发生故障时，估算修复费用，如果修复费用在预设的可接受范围内，执行修复动作，否则，更换设备。文献[261,262]针对修复非新的情况，对维修次数的优化问题等进行了讨论。文献[263]提出以维护成本率作为费用限制的阈值，在成本率达到某一阈值时更换设备，之前则进行维修。修复时间限制策略于 19 世纪 70 年代中期提出[264]，如果故障修复时间超过了某一阈值 t，不再进行维修，更换设备。文献[265]通过非参数估计方法优化维修时间阈值的估计值。文献[266]提出当设备出现故障，修复工作马上开始，如果修复能在 t 时刻内完成，完成修复动作；否则，拆除设备，订购新设备，设备到达后更换设备。

设备备件占用资金的减少是企业盘活资金、降低成本的重要手段。备件管理是为了按计划进行设备维修，缩短修理停机时间，减少修理费用而对备件的计划、生产、订货、采购、储存、供应、合理使用等方面进行的业务工作。备件管理是维护工作的重要组成部分，科学地储备和供应备件，不仅有助于按期完成维护工作，而且能够降低备件库存费用，提高经济效益。许多学者对备件库存问题[289-294]进行了研究。文献[267]针对需求量较低的贵重备件库存成本进行了研究，考虑了备件故障导致的贵重设备工作不正常导致巨大缺货成本情况。文献[268]研究了备件需求近似指数分布的备件库存问题，发展了现有的排队论库存模型，同时证明了此方法也能应用于优化用户专用的备件供应问题。文献[269]设计了一个以备件缺货发生概率为约束的模型，目标函数是使库存成本和采购成本最小化。Hopp 等学者[270]考虑了订货频率和综合服务水平，并提出了几种可实施的启发式算法，并明确了每种算法的最佳应用条件。Roger 等学者[271]研究了停止生产的设备备件需求的库存决策问题。文献[272]将备件需求分为关键需求和非关键需求，建议对关键备件采用保持较高水平库存。对于确定订货提前期的泊松分布需求，采用连续批量存储策略，而且通过仿真进行了验证。

许多维修模型假设系统故障后不能维修，或经过维修后能恢复到设备开始的最佳状态，但对很多实际系统来说这些假设一般是不成立的。在大多数情况下，随着设备性能的退化，执行维护后可能只会使设备修复到故障前的工作健康状态，或者修复到某个更好的工作健康状态，但不能修复如新。此外，对于部分维护模型，在维护过程中仅仅讨论了单故障的形式，而在设备的实际运行中，故障的形式是多样化的，针对不同的故障，采取的维护方式是不同的，从而也导致了不同的维护效果，因此多故障状态系统的讨论更符合实际应用中的故障模型。另外，有些维护模

复费用的限制分为两类。修复费用限制策略提出于19世纪60年代[260]，在该策略下，当设备发生故障时，估算修复费用，如果修复费用在预设的可接受范围内，执行修复动作，否则，更换设备。文献[261,262]针对修复非新的情况，对维修次数的优化问题等进行了讨论。文献[263]提出以维护成本率作为费用限制的阈值，在成本率达到某一阈值时更换设备，之前则进行维修。修复时间限制策略于19世纪70年代中期提出[264]，如果故障修复时间超过了某一阈值 t，不再进行维修，更换设备。文献[265]通过非参数估计方法优化维修时间阈值的估计值。文献[266]提出当设备出现故障，修复工作马上开始，如果修复能在 t 时刻内完成，完成修复动作；否则，拆除设备，订购新设备，设备到达后更换设备。

设备备件占用资金的减少是企业盘活资金、降低成本的重要手段。备件管理是为了按计划进行设备维修，缩短修理停机时间，减少修理费用而对备件的计划、生产、订货、采购、储存、供应、合理使用等方面进行的业务工作。备件管理是维护工作的重要组成部分，科学地储备和供应备件，不仅有助于按期完成维护工作，而且能够降低备件库存费用，提高经济效益。许多学者对备件库存问题[289-294]进行了研究。文献[267]针对需求量较低的贵重备件库存成本进行了研究，考虑了备件故障导致的贵重设备工作不正常导致巨大缺货成本情况。文献[268]研究了备件需求近似指数分布的备件库存问题，发展了现有的排队论库存模型，同时证明了此方法也能应用于优化用户专用的备件供应问题。文献[269]设计了一个以备件缺货发生概率为约束的模型，目标函数是使库存成本和采购成本最小化。Hopp等学者[270]考虑了订货频率和综合服务水平，并提出了几种可实施的启发式算法，并明确了每种算法的最佳应用条件。Roger等学者[271]研究了停止生产的设备备件需求的库存决策问题。文献[272]将备件需求分为关键需求和非关键需求，建议对关键备件采用保持较高水平库存。对于确定订货提前期的泊松分布需求，采用连续批量存储策略，而且通过仿真进行了验证。

许多维修模型假设系统故障后不能维修，或经过维修后能恢复到设备开始的最佳状态，但对很多实际系统来说这些假设一般是不成立的。在大多数情况下，随着设备性能的退化，执行维护后可能只会使设备修复到故障前的工作健康状态，或者修复到某个更好的工作健康状态，但不能修复如新。此外，对于部分维护模型，在维护过程中仅仅讨论了单故障的形式，而在设备的实际运行中，故障的形式是多样化的，针对不同的故障，采取的维护方式是不同的，从而也导致了不同的维护效果，因此多故障状态系统的讨论更符合实际应用中的故障模型。另外，有些维护模

型只考虑了设备的退化状态或者老化状态，没有综合两种衰退信息。其次，有些维护模型只考虑了设备的备件库存，没有考虑到维修人员对设备的维护模型的约束作用。因此，鉴于上述情况，本章结合前两章中单监测信息的在线健康预测和多监测信息的在线健康预测，提出了一个有多个不同故障状态的设备集成动态维修策略模型，充分探讨了考虑设备诊断信息和设备预测信息的设备维护问题。维护对象性能的退化是连续的进行过程，设备状态随着时间不断发生变化。通过第3、4章的健康指数获取及划分方法，可以将系统划分为多个离散的健康级别，将一个连续变化的退化过程简化成一个非连续的过程。状态间的转换概率可以从训练好的AHSMM中输出。这样就可以利用状态间的随机转移信息，使用离散马尔可夫链模型来描述维护对象的退化过程。同时，将设备划分为多个离散的健康状态，研究了设备不同健康状态和衰退信息对维护成本与维护时间的影响，考虑维护风险的影响，进一步完善了设备的集成动态维护模型，根据设定的目标，可以获得最优的设备维护策略，满足企业的生产效率要求，降低企业的维护成本，提高设备的利用率，延长设备的使用寿命。

5.2 衰退过程分析

设备衰退包括设备的退化与老化两个过程，对设备来说，如果没有经过任何维护，它不会转移到一个比当前更好的状态，而是转移到一个更差的状态。比如一台设备，如果在使用过程中，没有任何的维护，它内在的工作机制就会发生退化，或者说，这段时间没有使用，它同样会发生内在机制的一个退化，我们把这种现象称为设备的退化，如图5-2所示。

在本章中，使用上三角转移概率矩阵来描述设备的退化过程，即

$$P(h_t = j \mid h_{t-1} = i) = a_{ij} = 0, \forall j < i$$

设备在运转过程中，随着使用时间的增长，设备出现磨损，老化现象随之发生。因此，设备的故障风险就会增加。随着设备的持续运转，会越来越转移到更差的健康状态，我们把这种现象称为设备的老化，如零件的衔接处、零件之间的配合性等。

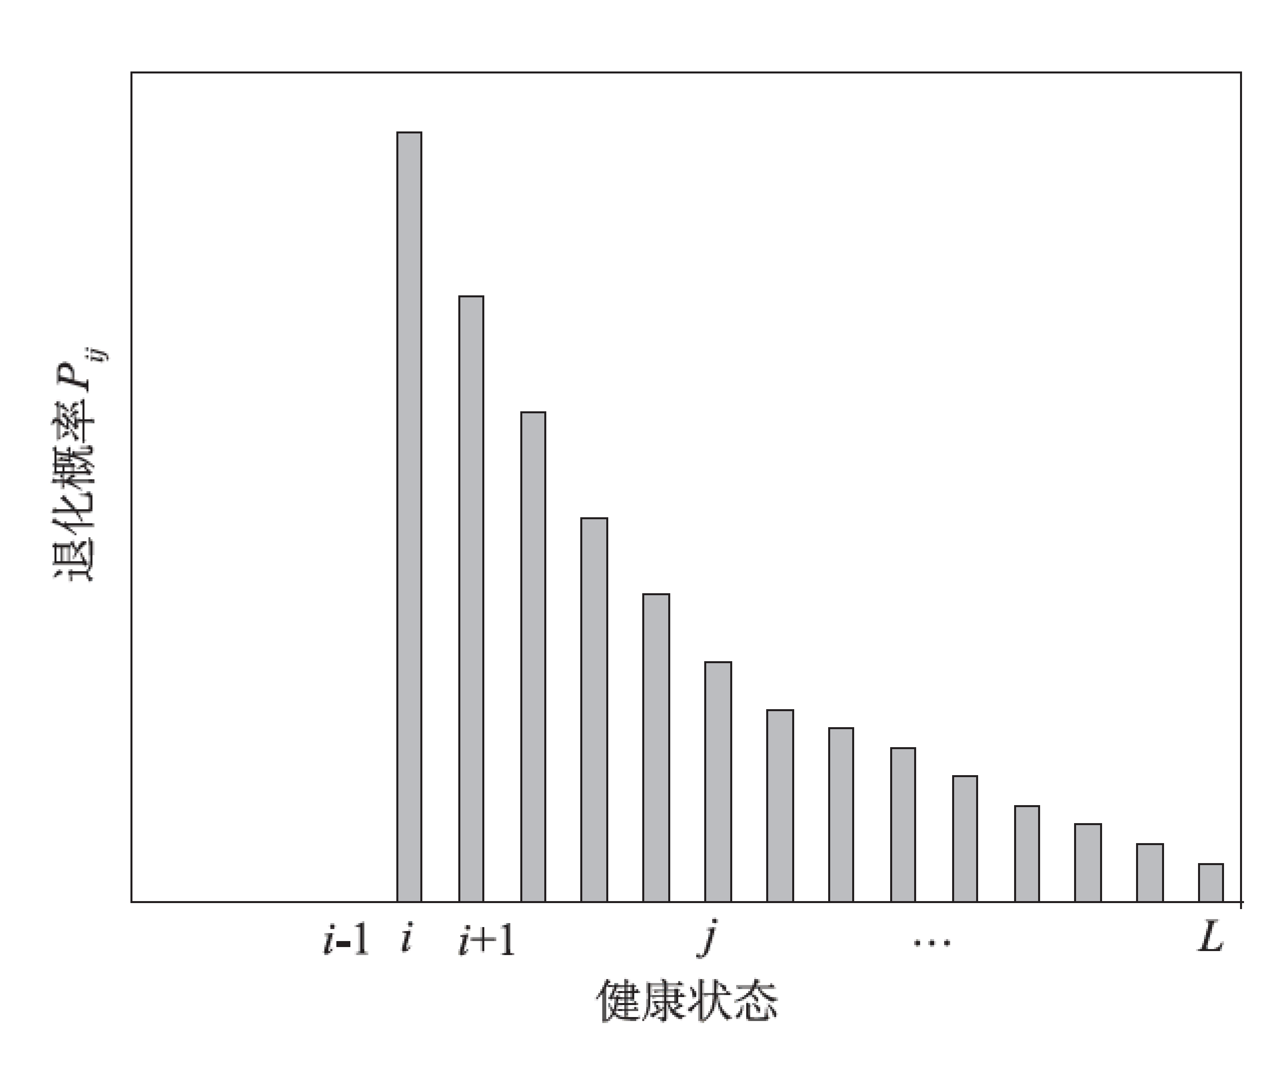
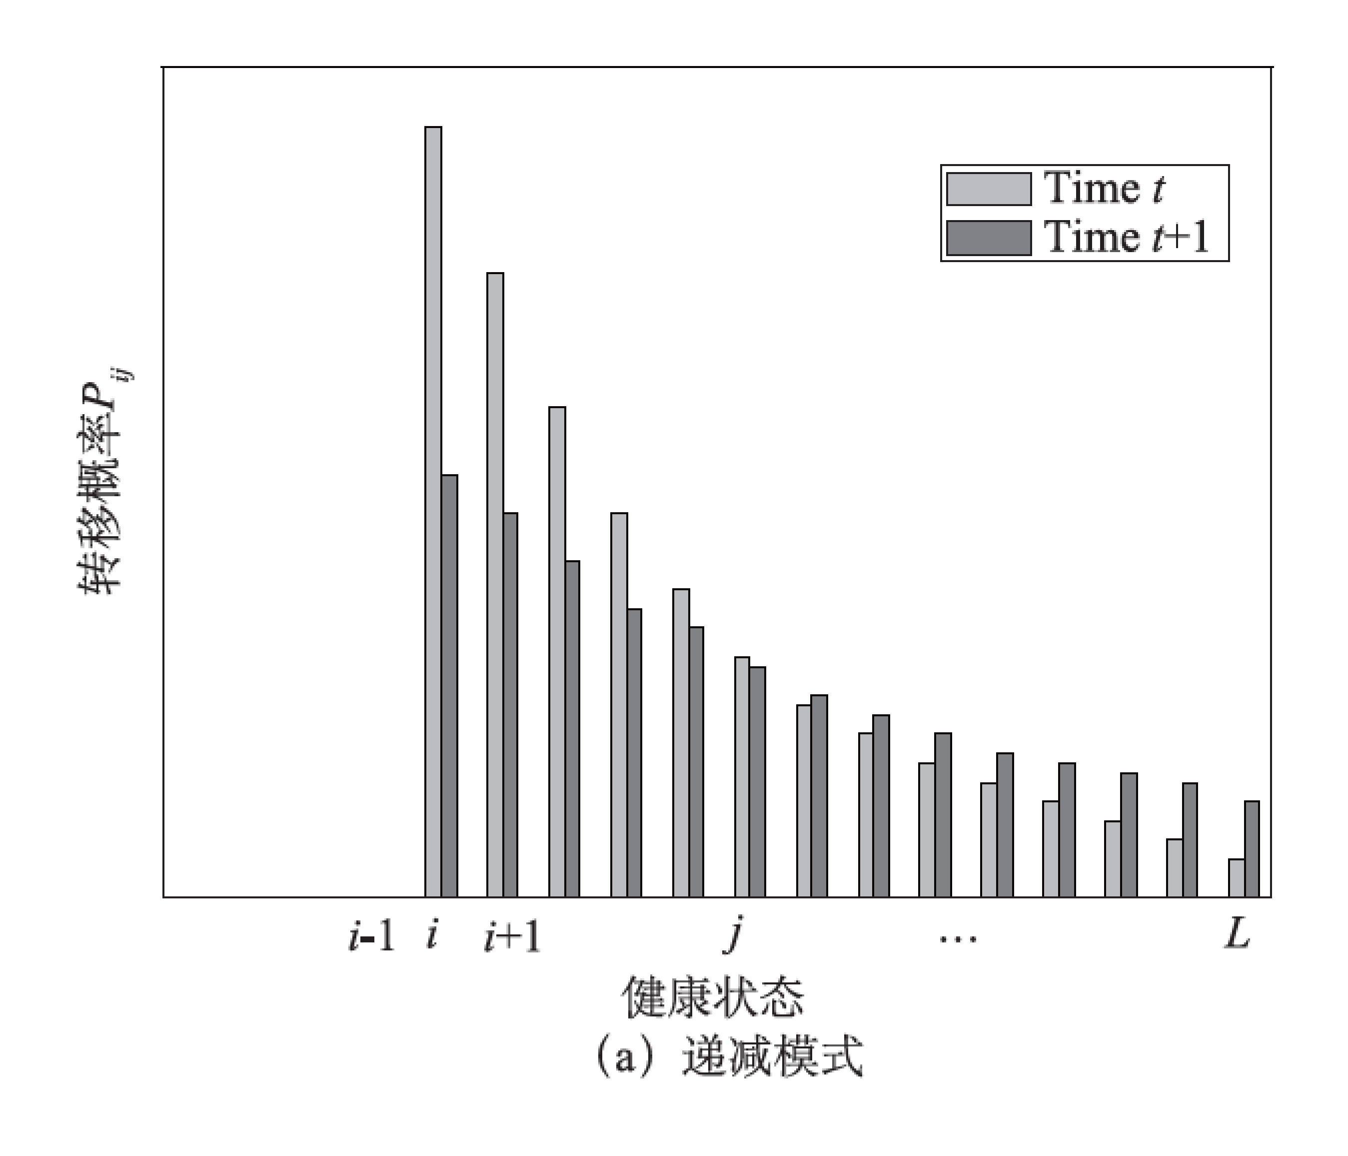


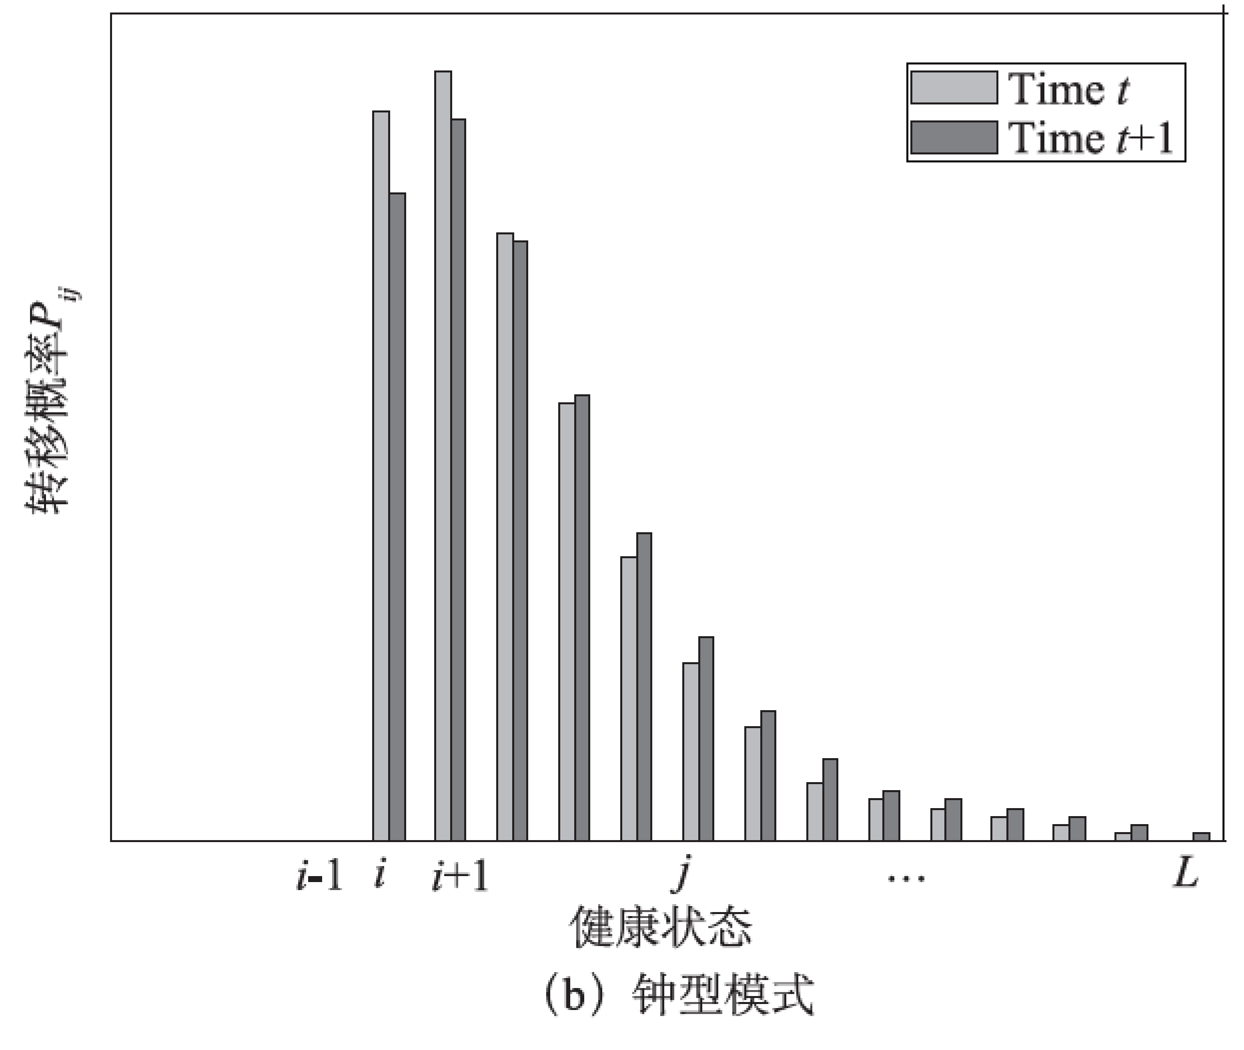
图 5-2 设备的退化概率转移

基于 HSMM 的设备健康预测模型设定状态之间的转移概率仅仅是状态依赖的，这就是说，设备转移到较差状态的概率不会随着设备使用年限而增加的。为了表达设备的老化现象，一个老化因子被集合到 HSMM 中去[61]，这个老化因子说明随着使用年限的增长，降低了设备停留在当前健康状态的概率，而增加了设备转移到一个较差状态的概率。通过一个迭代算法，用老化因子来更新从 HSMM 获得的初始状态概率转移矩阵，从而获得新的状态概率转移矩阵。尽管设备的健康状况通过采取维护措施，将有所改变，但是通过集合老化因子的 HSMM 所获得的健康状态仍然与真正的设备健康状态是最匹配的。随着由集合老化因子的 HSMM 获得设备分类信息，可以确定当前的设备健康状态，产生状态转移概率。

随着设备使用年龄的增加，设备的健康状态渐渐地转移到较差的状态，这种转移表示设备在后续使用过程中，会更加容易衰退。因而，在设备的衰退过程中，衰退模式分为递减模式（decrement mode）和钟形模式（bell mode），如图 5-3 所示。递减模式说明设备健康状态间的转移概率将逐渐降低，随着时间的增长，设备将逐渐发生衰退。钟形模式说明设备的几个初始健康状态之间的转移概率呈现增长的趋势，后续设备健康状态之间的转移概率呈现递减趋势。



(a) 递减模式



(b) 钟型模式

图 5-3　设备的衰退模式

5.3　维护动作与维护时间分析

按照第 4 章设计的基于 HSMM 的设备故障诊断与预测模型，对一台处于失效

机制下的设备，我们可以定义 L 个不同的状态序列：健康等级－1(例如，健康状态指标为 1，表示为 h_1)、健康等级－2(表示为 h_2)、……健康等级－($L-1$)(表示为 h_{L-1})、健康等级－L(表示为 h_L)。这里，等级－L 标识完全失效。其中，1 代表正常工作状态，L 代表失效状态，等级 2 至等级 $L-1$ 表示处于正常状态和失效状态之间的退化状态。则系统的健康状态划分为状态 $H=[1,2,\cdots,L]$，当设备的健康状态 $H=i$，$i\in[1,2,\cdots,L]$时，称设备处于状态 h_i，设备在状态 h_i的平均持续时间为 $t_{(i)}$。

当设备状态为 h_i时，可选择进行的预防性维护动作有非置换性维护和置换性维护，也可选择忽略此次维护时机，不采取任何动作。经过预防性维护后系统的改善情况分为两部分：①通过修理或更换，使原系统中的失效零件得以修复；②经过任意维修方式中的任意一种，使未失效的零件性能得以改善。

为了减缓设备性能的退化，可以采取不同的维护动作，如更换零件、不完全维护等。根据不同的设备退化状态，采取多种不同的维护动作，将设备状态优化至不同的目标值。为了体现维护动作对设备的改善作用，本章将设备的寿命设计为真实寿命与虚拟寿命。设备的真实寿命随着时间的推进而自然增加，不受维护动作的影响；而虚龄会因为采取了不同的维护动作而一定程度降低，即设备在执行了维护动作以后，设备的虚龄值会低于设备的真实寿命值。令 $D(h_i)$表示设备在状态 h_i的驻留时间。也就是说，当设备进入健康状态 h_i后，设备的虚龄将是设备停留在健康状态 h_i已存在的有效驻留时间和设备停留在健康状态 h_i以前所有健康状态的已存在的驻留时间之和。

令 $\overline{D}(h_i,n)$ 表示在第 n 个维护阶段，设备进入健康状态 h_i后，已经存在的驻留时间，则

$$D(h_i)=\mu(h_i)+\rho\sigma^2(h_i) \tag{5-1}$$

$$\rho=\left(T-\sum_{i=1}^{N}\mu(h_i)\right)\Big/\sum_{i=1}^{N}\sigma^2(h_i) \tag{5-2}$$

$$\overline{D}(h_i,n)=(1-a_{ii})D(h_i) \tag{5-3}$$

其中，$\mu(h_i)$是健康状态 h_i的驻留概率密度函数的均值，$\sigma^2(h_i)$是健康状态 h_i的驻留概率密度函数的方差。T 表示设备的全寿命，且 $T=\sum_{i=1}^{N}D(h_i)$。

因此，基于方程(5-1)～方程(5-3)，在第 n 个维护阶段，可以计算设备进入健康状态 h_i的虚龄 t_n，计算公式如下：

$$t_n = \begin{cases} \overline{D}(h_i, n) & i = 1 \\ \overline{D}(h_i, n) + \sum_{j=1}^{i-1} D(h_i) & i > 1 \end{cases} \tag{5-4}$$

当设备的健康状态为 h_i 时，有多种不同的维护动作可以选择，具体的维护动作集合表示为

$$\begin{aligned} \mathrm{PM}_i = & \{\mathrm{PM}_0, \mathrm{PM}_{ii}, \mathrm{PM}_{Re}\} \cup \{\mathrm{PM}_{ij} \mid 1 \leqslant j \\ & \leqslant i-1, k \in H\}, i = 2, 3, \cdots, L-1 \end{aligned} \tag{5-5}$$

其中，

PM_0 表示忽略设备的维护，不采取任何维护动作。

PM_{ii} 表示设备的保养维护(小修)，进行润滑、调节、除尘等一般性保养工作，使设备停留在当前状态 h_i 的概率不因为设备衰退的作用而降低。

PM_{ij} 表示设备的维修(大修)，即非置换性维护，对设备进行修复，修复部分部件的损耗。维修的目的就是让设备从当前健康状态 h_i 恢复到一个更好的健康状态 h_j，在这种情况下，系统的虚龄将降低。

PM_{Re} 表示设备的更换，即置换性维护，直接用新的零部件更换发生故障或者损耗的设备零部件，在这种情况下，设备将恢复到初始健康状态 h_1。

根据设备具体的健康状态，采取不同的维护动作，将设备修复到不同的目标和不同的健康状态，如图 5-4 所示。因此，不能忽略设备的具体维护时间和更换时间，大量地采取维护动作固然可以保持设备的可靠性，但是设备的利用率会降低。对于设备的利用率：

$$\begin{aligned} Au &= \frac{\text{Total_uptime}}{\text{Total_uptime} + \text{Total_downtime}} \\ &= \frac{\sum T_w}{\sum T_w + \sum T_{\mathrm{PM1}} + \sum T_{\mathrm{PM2}} + \sum T_{Re}} \end{aligned} \tag{5-6}$$

Au 表示设备利用率，T_w 描述了连续采取两次维护间的工作时间(w 是连续工作时间段的标记符号)。T_{PM1} 是执行小修维护 PM_{ii} 所需要的时间，T_{PM2} 是执行维修动作 PM_{ij} 所需要的时间，T_{Re} 是执行置换动作 PM_{Re} 所需要的时间。

在本章中，采取了不同的维护动作来减缓设备的衰退，包括忽略、非置换性维护、更换等。除了忽略和更换维护，非置换性维护在执行维护过程中，存在一定的风险。也就是说，在执行非置换性维护后，设备不一定会修复到期望的健康状态。例如，在某时刻，当设备处于健康状态 h_i 时，采取维修动作 PM_{ij} 对设备进行维护

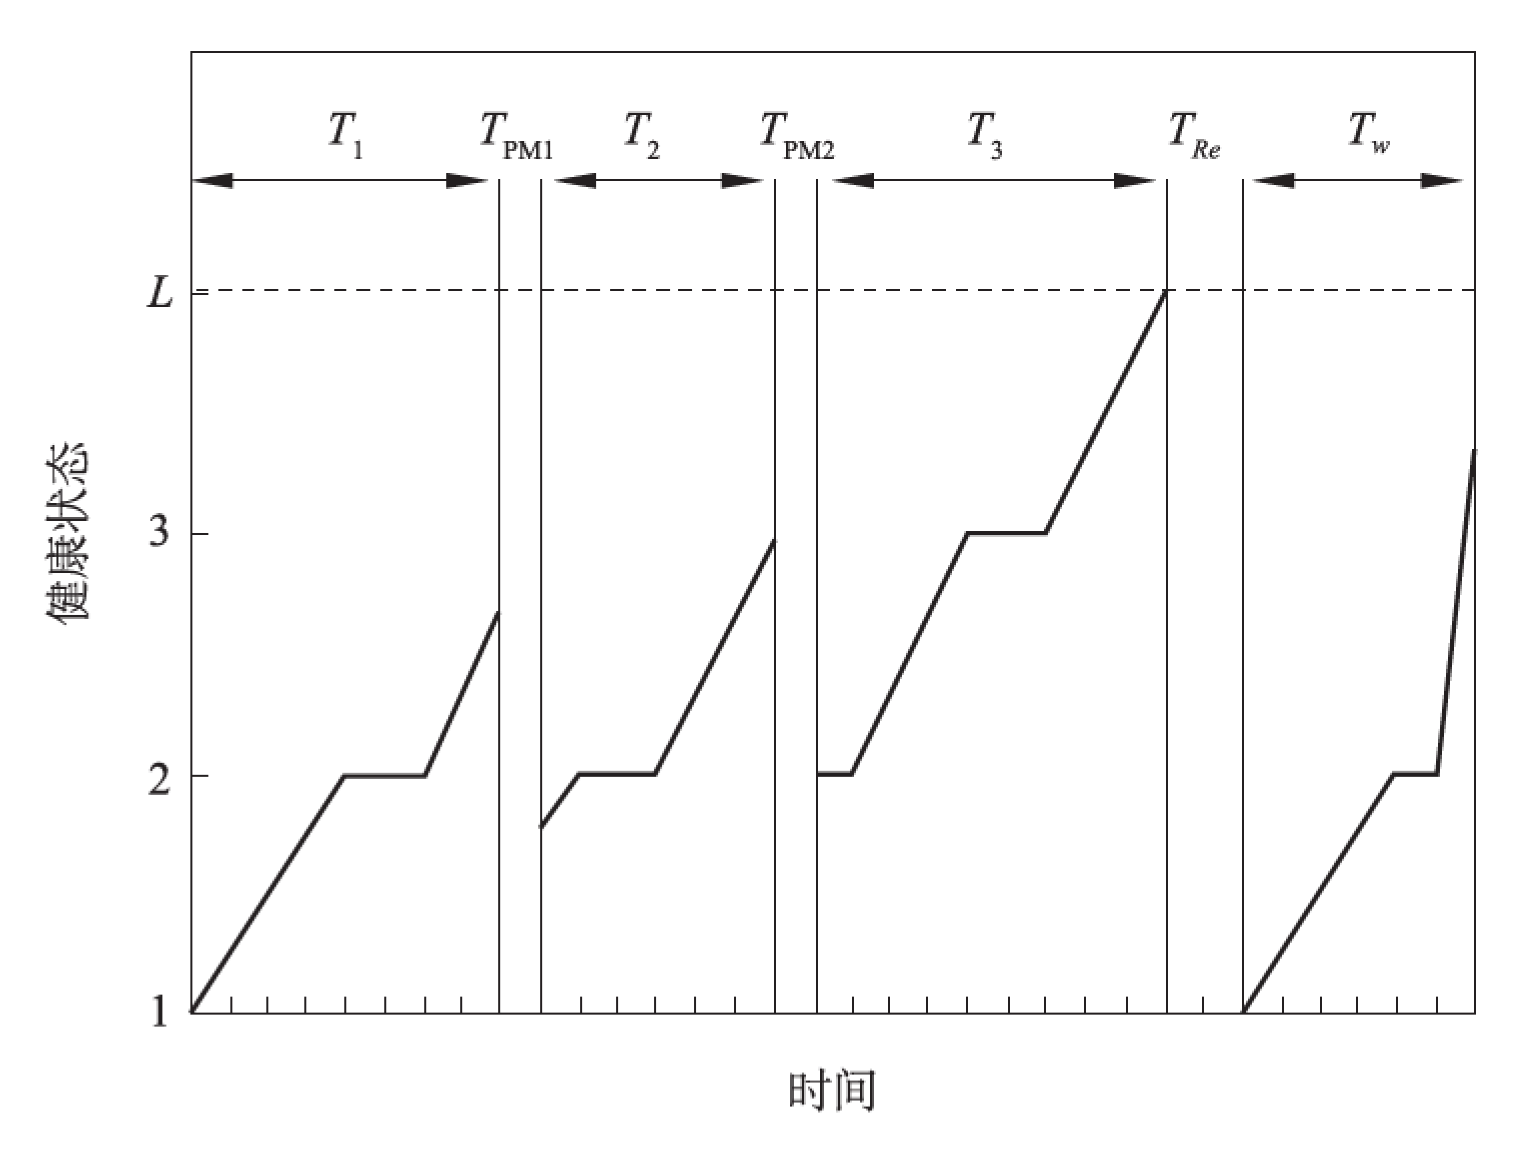


图 5-4　维护时间关系

后，预期维护目标是恢复设备的健康状态到一个期望的更好的健康状态 h_j，然而，在采取维护动作 PM_{ij} 后，实际的健康状态 h_i 并没有恢复到期望的健康状态 h_j，而是恢复到一个比健康状态 h_j 差的状态。随着设备寿命的增长，设备将出现退化和老化现象，因此，设备的维护风险也将增加。也就是说，实际的设备维护并不能达到期望的维护效果。

5.4　集成动态维护模型

5.4.1　基本假设和符号

针对设备的性能退化过程，设备的生命周期根据划分规则划分为多个健康状态，提出集成的动态维护模型来进行设备的维护决策，为了更好地对设备进行维护，对维护模型的一些基本假设如下。

(1) 基于 HSMM 的诊断和预测模型，获得设备的实时健康状态 $h_t \in [1,2,\cdots,L]$。如果不对设备执行维护动作，在设备的寿命增长过程中，将以更大的转移概率向更差的状态进行转移。

(2) 设备是被定期实时监测的，根据新的设备监测数据，执行相应的不同的维护动作。

(3) 设备处于状态 i 时，选择执行的维护动作有：

$$\mathrm{PM}_i = \{\mathrm{PM}_0, \mathrm{PM}_{ii}, \mathrm{PM}_{Re}\} \cup \{PM_{ij} \mid 1 \leqslant k \leqslant i-1, k \in S\},$$
$$i = 2,3,\cdots,L-1$$

当设备进入故障状态 L 时，非置换性的维护动作不能再被采取，而应采取相应的更换维护动作。

(4) 随着设备寿命的增加，设备将转移到更差的健康状态。

(5) 如果在时刻 t，不采取任何维护动作，则在此时刻下，设备没有维护成本和维护时间。

(6) 设备执行置换维护时，不管设备处于何种状态，采取该维护动作产生的成本 C_{Re} 与置换时间 t_{Re} 不会发生变化。对于非置换维护所产生的维护成本为 C_{PM}，维护时间为 t_{PM}。

(7) C_{Inv} 代表了备件成本，当所采取的维护策略发生变化时，相对应的备件成本 C_{Inv} 也会发生变化。当设备向较差的健康状态转移时，对应的采取维修维护动作所需要的备件将会增加，因此，对应的备件成本也变得越高。

(8) 对应于设备健康状态 i 和设备的虚龄，设备的故障成本 C_F 是一个非递减的函数。在不同的设备健康状态，设备的故障成本是不一样的，随着健康状态的退化和设备寿命的增加，设备的故障成本也随之提高。

对于维护模型，本章中将用到以下符号或标记：

符号	描述
C_{Sy}	系统成本
C_M	系统维护成本
C_F	系统故障成本
C_f	故障独立成本
C_o	故障依赖成本
C_{Av}	资源成本
C_{Inv}	备件成本
C_p	维护人员成本
C_{order}	备件订货成本
C_h	备件存储成本
C_s	备件缺货成本

续表

符号	描述
CA	设备停机成本
c_{item}	每单位备件的可变成本
c_h	每单位备件的储存成本
b_n	第 n 个维护阶段的订货数量
K	每次订货的固定成本
y_n	第 n 个维护阶段的初始库存水平
y	总的维修人员数量
c_p	缺少维修人员时的惩罚系数
F	设备的维护阶段数
$c_{f,i}$	当设备健康状态为 i 时的故障独立成本
$c_o(i,t_n)$	在时间 t_n设备健康状态为 i 时的故障依赖成本
$P_{ji}(t_n)$	当设备虚龄为 t_n时，从健康状态 j 转移到健康状态 i 的概率
$c_{m,i}$	当设备健康状态为 i 时的维护独立成本
$c_M(a_n\|i)$	当设备健康状态为 i 时，采取维护动作 a_n产生的维护依赖成本
$r(a_n\|i)$	当设备健康状态为 i 时，采取维护动作 a_n产生的备件需求数量
$p(a_n\|i)$	当设备健康状态为 i 时，采取维护动作 a_n产生的维护人员需求数量
$C_T(n,F-n,t_n,a\|i)$	采取维护动作 a，未来 $F-n$ 维护阶段的期望总成本
$C(n,F-n,t_n,a\|i)$	采取维护动作 a，未来 $F-n$ 维护阶段的期望总系统成本和资源成本
$T(n,F-\text{n},t_n,a\|i)$	采取维护动作 a，未来 $F-n$ 维护阶段的期望总维护时间
$C_{Av}(y_n,a_n,b_n\|i)$	当设备健康状态为 i 时，第 n 个维护阶段的资源成本
b	衰退形状因子(即设备状态转移概率形状因子)
d	停机因子(即停机成本系数)
r	维护风险因子(即维护风险)

5.4.2　维护成本分析

对于本章的维护模型，应考虑两个重要的需要优化的维护目标：维护总成本 C_{total}和设备利用率 Au。对于设备的维护，需要平衡设备的维护成本和设备利用率之间的关系，根据两者的优化目标，对设备执行最优的维护策略。

设备采取的维护动作对企业的经济效益会产生重要的影响，在设备的维护建模中，维护成本 C_M、操作成本 C_o和维护资源成本 C_{Av}被考虑。而且，维护成本 C_M包括置换成本 C_{Re}和非置换成本 C_{PM}两大类。设备的成本是直接与设备所采取的

维护动作相关联的，包括置换成本（PM_{Re}）、日常维护成本（PM_{ii}）、维修维护成本（PM_{ij}），以上这些成本，统称为设备的维护成本（C_M）。与设备所采取的维护动作间接相关的成本包括设备故障成本（C_F）和设备的资源成本（C_{Av}）。通过采取不同的维护动作，设备可以减缓它的退化与老化，因此，设备衰退所引起的设备故障成本将减少，这就说明了设备的故障成本也是与设备的维护相关联的，是设备长期平均总成本的一部分。另一方面，为了有效地执行设备的维护动作，也需要不同的维护资源。对应各种不同的维护策略，需要利用不同的资源，因而，产生不同的资源成本。因此，在设备长期的平均总成本中，资源成本也被作为维护模型的一部分。设备的故障成本是与设备的健康状态相关联的，而设备的资源成本是与所采取的维护动作相关联的。

因此，对于设备的总成本目标，包括系统成本 C_{Sy}（包括设备的维护成本 C_M 和设备的故障成本 C_F）和设备的资源成本 C_{Av}。同时，在考虑设备利用率的基础上，设备的维护动作所引起的停机产生的停机成本 CA 也包含在设备的维护成本模型中，停机成本 CA 是与设备的维护动作持续时间 T_M 和设备停机成本系数 d 相关的，因此，综合考虑设备成本和设备利用率的总的维护模型成本目标可以表示为

$$\mathrm{Min}C_{\mathrm{Total}} = C_{Sy} + C_{Av} + CA = C_M + C_F + C_{Av} + T_M \times d \tag{5-7}$$

1. 维护模型的系统成本

目前，在工业中，所关注的问题包括降低设备的操作支持成本和提高设备的安全性。设备的维护直接影响设备的利用率和企业的生产效率。对设备维护来说，这方面的直接成本被定义为系统成本，它包括设备的故障成本和设备的维护成本两个方面。因为设备的故障成本可能会涉及设备故障的识别，在发生故障的时刻，设备的备件数量不足，也可能由于设备故障发生的无计划性，导致缺少设备的维护人员，因此，设备的故障成本可能会高于设备的维护成本。然而，如果执行了大量的维护动作，也将导致设备维护成本的增加。因此，设备的系统成本是设备的故障成本和设备的维护成本之和。设备系统成本模型可以表示为

$$C_{Sy} = C_F + C_M \tag{5-8}$$

设备的故障成本是由两部分组成，分别是设备的故障独立成本（C_f）和设备的故障依赖成本（即操作成本 C_o）。设备的故障独立成本描述了不同故障所产生的固定成本，如设备冷却、诊断、拆卸、重新组装、启动和加热所产生的成本。设备的故障依赖成本是指对发生故障零部件的维修或者置换操作成本。因此，设备的故

障成本模型可以表示为

$$C_F = C_f + C_o = c_{f,i} + \sum_{j=1}^{i} P_{ji}(t_n) c_o(i, t_n) \tag{5-9}$$

其中，$c_{f,i}$表示当设备健康状态为i时的设备的故障独立成本；$c_o(i,t_n)$代表设备处于健康状态i时，采取维护动作a_n所产生的设备故障依赖成本；$P_{ji}(t_n)$描述了设备虚龄是t_n时，从状态j到状态i的状态转移概率。

与设备的故障成本相似，设备的维护成本也是由两部分组成，分别是设备的维护独立成本和设备的维护依赖成本。设备的维护独立成本描述了采取不同的维护动作所产生的固定成本，如设备的停机、降温、拆卸、重新组装、启动和加热所产生的成本。设备的维护依赖成本是指实际采取的设备维护动作所产生的成本。因此，设备的维护成本模型可以表示为

$$C_M = c_{m,i}\delta(a_n) + c_M(a_n \mid i) \tag{5-10}$$

其中，$c_{m,i}$表示当设备健康状态为i时的设备的维护独立成本；对于$\delta(a_n)$的取值，如果采取维护动作a_n，则$\delta(a_n)$的取值为1，否则为0；$c_M(a_n|i)$代表了设备处于健康状态i时，采取维护动作a_n所产生的设备维护依赖成本。

基于方程(5-8)～方程(5-10)，总的设备维护模型的系统成本可以表示为

$$C_{Sy} = C_M + C_F = c_{m,i} + c_M(a_n \mid i) + c_{f,i} + \sum_{j=1}^{i} P_{ji}(t_n) c_o(i, t_n) \tag{5-11}$$

2. 维护模型的资源成本

在执行设备的维护策略过程中，所需要的资源主要包括采取维护动作所需要的设备备件和设备的维护维修人员两部分。如果设备的备件和设备的维护维修人员满足维护动作需求，则设备的维护策略才能有效地执行。在缺少设备维护资源的情况下，设备的维护动作不能被有效地执行，从而，会产生更多的设备的停机成本。因此，将设备的资源信息集成到设备的维护模型中是非常重要的。设备的资源成本主要是由设备的备件成本和设备的维护维修人员成本所组成的，因此，总的设备维护模型的资源成本可以表示为

$$C_{Av} = C_{Inv} + C_p \tag{5-12}$$

设备的备件成本主要包括备件订货成本(C_{order})、备件的储存成本(C_h)和备件的缺货成本(C_s)。因此，设备的备件成本模型可以表示为

$$C_{Inv} = C_{\text{order}} + C_h + C_s \tag{5-13}$$

设备备件的订货成本包含固定备件订货成本和可变备件订货成本，因此，备件

的订货成本模型可以表示为

$$C_{\text{order}} = K\delta(b_n) + c_{\text{item}} \times b_n \tag{5-14}$$

其中，$\delta(b_n)$的取值依赖于b_n的值是否为0，如果b_n等于0，则$\delta(b_n)$的取值为1，否则，$\delta(b_n)$的取值为0；K是每次备件订货时的固定订货成本，因此，$K\delta(b_n)$用来表示备件总的固定订货成本；c_{item}表示每单位备件的可变订货成本，b_n表示在第n个维护阶段的订货数量，因此，$c_{\text{item}} \times b_n$表示在第$n$个维护阶段总的备件订货可变成本。

设备备件的储存成本是与备件的库存水平及备件的需求数量相关的，因此，设备的备件储存成本模型可以表示为

$$\begin{cases} C_h = \max\{0, c_h[y_n + b_n - r(a_n \mid i)]\} \\ y_n = y_{n-1} + b_{n-1} - r(a_{n-1}) \end{cases} \tag{5-15}$$

其中，y_n表示第n个维护阶段的初始备件库存水平；$r(a_n|i)$描述了当设备健康状态为i时，通过采取维护动作a_n所产生的设备备件的需求数量；c_h表示每单位设备备件的储存成本。

设备备件的缺货会影响设备维护动作的有效执行，进而，影响设备的生产使用，对于出现故障的设备部件，由于设备备件的缺少，不能及时得到有效的维护维修。因此，为了避免频繁的设备备件的缺货，设备备件的缺货成本也作为设备维护成本模型的一部分。c_s表示每单位的备件缺货成本，因此，设备备件缺货成本模型可以表示为

$$C_s = \sum_{j=1}^{i} P_{ji}(t_n)\max\{0, c_s[r(a_n \mid i) - y_n - b_n]\} \tag{5-16}$$

基于方程(5-13)～方程(5-16)，总的设备维护模型的备件成本模型可以表示为

$$\begin{aligned} C_{Inv} = {} & K\delta(b_n) + c_{\text{item}} \times b_n + \max\{0, c_h[y_n + b_n - r(a_n \mid i)]\} + \\ & \sum_{j=1}^{i} P_{ji}(t_n)\max\{0, c_s[r(a_n \mid i) - y_n - b_n]\} \end{aligned} \tag{5-17}$$

在维护资源成本模型中，如果执行维护动作所需要的人力资源不能满足需求，就应定义维护人员的缺少所对应的每个设备健康状态的惩罚成本。人力惩罚成本是与在执行维护动作时所需要的人力数量及缺少维护人员时的惩罚系数相关联的。在维护人员成本模型中，令c_p表示惩罚系数，y表示总的维护人员的数量，$p(a_n|i)$表示当设备处于健康状态i时，通过采取维护动作a_n所产生的维护人员需求数量。因此，总的设备维护模型的维护人员成本模型可以表示为

$$C_p = \sum_{j=1}^{i} P_{ji}(t_n)\max\{0, c_p[p(a_n \mid i) - y]\} \tag{5-18}$$

基于方程(5-12)、方程(5-17)和方程(5-18)，总的设备维护模型的资源成本模型表示为

$$\begin{aligned} C_{Av} &= C_{Inv} + C_p \\ &= K\delta(b_n) + c_{\text{item}} \times b_n + \max\{0, c_h[y_n + b_n - r(a_n \mid i)]\} + \\ &\quad \sum_{j=1}^{i} P_{ji}(t_n)[\max\{0, c_s(r(a_n \mid i) - y_n - b_n)\} + \\ &\quad \max\{0, c_p[p(a_n \mid i) - y]\}] \end{aligned} \tag{5-19}$$

5.4.3 基于动态规划算法维护策略优化模型

在本章内容中，集成动态维护模型的阶段，对于未来无穷的周期，如果考虑最优的设备维护策略是没有多大意义的，在设备的使用过程中，时间越长，周期越多，设备的不确定性就会越大，从而，设备健康预测的精度就会降低。对于集成的动态维护模型，对设备的整个维护建模过程的划分代表了维护模型的维护周期阶段。为了按时间的先后顺序进行集成动态维护建模和求解最优的维护策略，需要根据实际的时间顺序划分模型的维护阶段。由于在两个监测时刻点之间，具有固定的时间长度，因此，对于每一段的时间间隔，被认为是一个维护阶段。因此，本章中定义常数 $F=\{1,2,\cdots,F_{\max}\}$（$F_{\max}$ 表示模型维护阶段的最大值）来表示设备维护模型的维护阶段，因此，集成动态维护模型的意义就在于求解在未来 F 个维护阶段内的最优设备维护策略。通过对设备维护阶段的划分，设备的维护问题转化为阶段决策问题，在每个阶段的每个设备监测时刻，对设备进行维护决策和采取相应的维护动作，采取的维护动作要使维护目标最优化，以保证在每个阶段的维护策略都是最优的。总的设备维护最优策略就是每个阶段最优策略的集合。

在设备的每个维护阶段的初始时刻，本章提出的维护模型的健康状态代表设备的一个自然健康状况。对于设备的健康状态，主要表明了设备的演化过程的特征，而且，在给定某个设备维护阶段的健康状态时，该维护阶段的设备健康状态的变化与以前的维护阶段的设备健康状态的演化是不相关的。另外，在维护模型建立过程中，状态是可以直接或者间接进行观测的。集成动态维护模型建模过程中，所涉及的状态 $h_i=\{1,2,\cdots,L\}$，通过第 3 章和第 4 章的健康预测

模型获得。

对于集成动态维护模型的决策，当获得了某个维护阶段的设备健康状态以后，对于该维护阶段，应根据设备的健康状态执行不同的维护动作，在执行维护动作后，设备将转移到下个维护阶段的某个健康状态，这就是设备的维护决策过程。用决策变量来描述维护决策，对于设备维护决策的集合则表示了决策变量的可取值范围。基于方程(5-5)，最优决策是选择最优的维护动作，因此，可供选择的维护动作集合：

PM_{i0}表示设备无维护，维护模型不受影响；

PM_{ii}表示在设备进行保养维护后，设备不发生状态之间的转移，设备的状态仍然停留在当前状态，同时，设备的虚龄降低为

$$\sum_{k=1,2,\cdots,i-1} t_{(k)} + E[\lambda(t_n - \sum_{k=1,2,\cdots,i-1} t_{(k)}) + 0.5]$$

PM_{ij}表示在设备进行大修维护后，设备将从当前的健康状态恢复到一个更好的健康状态，同时，设备的虚龄降低为：

$$\sum_{k=1,2,\cdots,j-1} t_{(k)} + E[\lambda(t_n - \sum_{k=1,2,\cdots,j-1} t_{(k)}) + 0.5]$$

PM_{iRe}表示在设备进行置换维护后，设备的健康状态将恢复到设备的初始状态h_1，同时，设备的虚龄成为0。

在上述维护动作中，在健康状态k下，$t_{(k)}$代表了其驻留时间。通过方程(5-1)和方程(5-2)可以获得每个设备健康状态的驻留时间($t_{(k)}$)。$E[x]$是下取整函数，$E[x+0.5]$是对x执行四舍五入的取整操作。λ代表了设备的维护执行效用函数($\lambda \in [0,1]$)。$\lambda=0$，执行维护动作后，完成修复设备；$\lambda=1$，表示对设备采取维护动作后，维护动作没有任何效用，在当前健康状态下，设备的虚龄将保持不变。

对于集成动态维护模型的最优值的函数，它是衡量设备维护过程优劣的一个数量指标。在执行设备的第n次检测时，设备处于健康状态i，且设备虚龄是t_n，因此，设备在F个维护阶段的最优值函数可以表示为

$$\text{Min } C_T(n,F-n,t_n,a|i)=C(n,F-n,t_n,a|i)+T(n,F-n,t_n,a|i)\times d \quad (5\text{-}20)$$

其中，a是在第n个维护阶段，对设备所采取的维护动作。t_n是第n个维护阶段设备的虚龄。在维护动作a对应的未来$F-n$个期间内，$C_T(n,F-n,t_n,a|i)$表示期望总成本，$T(n,F-\text{n},t_n,a|i)$表示期望总维护时间。$C(n,F-n,t_n,a|i)$是维护动作a对应的未来$F-n$个期间内的包括系统成本和资源成本的期望总成本。

提出模型的设备各状态之间的相互转化关系，见第2章和第3章的内容。

对应 F 个维护阶段，令 $C_{Av}(y_n, a_n, b_n | i)$ 表示当设备的健康状态为 i 时，第 n 个维护阶段的资源成本。则在 n 个维护阶段以后，期望总资源成本可以表示为

$$C_{Av}(n, F-n, y_n, a_n, b_n \mid i) = C_{Av}(y_n, a_n, b_n \mid i) + \sum_{j=i,i+1,\cdots,L} P_{ij}(t_n)\{C_{Inv}(n+1, y_{n+1}, F-n-1, a_{n+1}, b_{n+1} \mid j)^*\} \tag{5-21}$$

基于方程(5-15)和方程(5-21)，可得维护动作 a 对应的未来 $F-n$ 个维护阶段内期望资源成本为

$$\begin{aligned} & C_{Av}(n, F-n, a_n, b_n \mid i) \\ & = C_{Inv}(n, F-n, a_n, b_n \mid i) + C_p(n, F-n, a_n, b_n \mid i) \\ & = K\delta(b_n) + c_{\text{item}} \times b_n + \max\{0, c_h(y_n + b_n - r(a_n \mid i))\} + \sum_{j=1}^{i} P_{ji}(t_n)[\max\{0, c_s(r(a_n \mid i) - \\ & \quad y_n - b_n)\} + \max\{0, c_p(p(a_n \mid i) - y)\}] + \sum_{j=i,i+1,\cdots,L} P_{ij}(t_n)\{C_{Inv}(n+1, F-n-1, \\ & \quad y_n + b_n - r(a_n \mid i), a_{n+1}, b_{n+1} \mid j)^*\} \end{aligned} \tag{5-22}$$

即，在第 n 个维护时刻的资源总成本由两部分组成：一个是 n 个维护阶段内的资源成本；另一个是 $n+1$ 时刻后的 $F-n$ 个维护阶段的期望总资源成本。

针对维护动作 a，在未来 $F-n$ 个维护阶段，设备的期望总成本可以表示为

$$\begin{aligned} & \mathrm{C}(n, F-n, t_n, a \mid i) \\ & = C_M(a) + C_F(i, t_n) + C_{Av}(i, a, t_n) + \\ & \quad \sum_{j=i,i+1,\cdots,L} P_{ij}(t_n)\{\mathrm{C}(n+1, F-n-1, t_n+1, a' \mid j)^*\} \end{aligned} \tag{5-23}$$

基于方程(5-23)，在第 n 个维护时刻的期望总成本由两部分组成：一个是 n 个维护阶段内的故障成本、维护成本和资源成本之和；另一个是 $n+1$ 时刻后的所有维护阶段的期望总故障成本、维护成本和资源成本之和。

针对维护动作 a，在未来 $F-n$ 个维护阶段，设备的期望总维护时间可以表示为

$$\begin{aligned} & T(n, F-n, t_n, a \mid i) \\ & = t(a) + \sum_{j=i,i+1,\cdots,L} P_{ij}(t_n)\{T(n+1, F-n-1, t_n+1, a' \mid j)^*\} \end{aligned} \tag{5-24}$$

在第 n 个维护时刻的期望总维护时间由两部分组成：一个是 n 阶段内维护动作所需要的维护时间；另一个是 $n+1$ 时刻后的所有维护阶段的期望总维护时间。

针对不同的维护动作，设备维护模型的目标函数表示为

$$C(n,F-n,t_n,a\mid i)=$$
$$\begin{cases}C_F(i,t_n)+C_{Av}(n,F-n,\mathrm{PM}_0,b_n\mid i)+\sum_{j=i,i+1,\cdots,L}P_{ij}(t_n)\{C(n+1,F-n-1,\\ t_n+1,a'\mid j)^*\} & a=\mathrm{PM}_0\\ C_M(\mathrm{PM}_{ii})+C_F(i,t')+C_{Av}(n,F-n,\mathrm{PM}_{ii},b_n\mid i)+\sum_{j=i}^{L}r^{j-i}(1-r)C(n,F-n,\\ t'+1,a'\mid j)^*+r^{L-i}C(n,F-n,t'+1,\mathrm{PM}_{jL}\mid L)^* & a=\mathrm{PM}_{ii}\\ C_M(\mathrm{PM}_{ij})+C_F(j,t^*)+C_{Av}(n,F-n,\mathrm{PM}_{ij},b_n\mid i)+\sum_{q=j}^{L}r^{q-j}(1-r)C(n,F-n,\\ t^*+1,a'\mid q)^*+r^{L-j}C(n,F-n,t^*+1,\mathrm{PM}_{qL}\mid L)^* & a=\mathrm{PM}_{ij}\\ C_M(\mathrm{PM}_{Re})+C_F(1,0)+C_{Av}(n,F-n,\mathrm{PM}_{Re},b_n\mid i)+\sum_{j=i,i+1,\cdots,L}P_{1j}(0)\\ \{C(n+1,F-n-1,1,a'\mid j)^*\}\\ t'=\sum_{k=1,2,\cdots,i-1}t_{(k)}+E(\lambda(t_n-\sum_{k=1,2,\cdots,i-1}t_{(k)})+0.5)\\ t^*=\sum_{k=1,2,\cdots,j-1}t_{(k)}+E(\lambda(t_n-\sum_{k=1,2,\cdots,j-1}t_{(k)})+0.5)\\ b_n=\operatorname{argmax}\{C_{Av}(n,F-n,y_n,a_n,b_n\mid i)\} & a=\mathrm{PM}_{Re}\end{cases}\tag{5-25}$$

$$T(n,F-n,t_n,a\mid i)=$$
$$\begin{cases}\sum_{j=i,i+1,\cdots,L}P_{ij}(t_n)(T(n+1,F-n-1,t_n+1,a'\mid j)^*) & a=\mathrm{PM}_0\\ t(\mathrm{PM}_{ii})+\sum_{j=i}^{L}r^{j-i}(1-r)T(n,F-n,t'+1,a'\mid j)^*+\\ r^{L-i}T(n,F-n,t'+1,\mathrm{PM}_{jL}\mid L)^* & a=\mathrm{PM}_{ii}\\ t(\mathrm{PM}_{ij})+\sum_{q=j}^{L}r^{q-j}(1-r)T(n,F-n,t^*+1,a'\mid q)^*+\\ r^{L-i}T(n,F-n,t^*+1,\mathrm{PM}_{qL}\mid L)^* & a=\mathrm{PM}_{ij}\\ t(\mathrm{PM}_{Re})+\sum_{j\in H}\{P_{1j}(0)(T(n+1,F-n-1,0,a'\mid j)^*)\} & a=\mathrm{PM}_{Re}\end{cases}\tag{5-26}$$

集成动态维护模型可以被转换为一个双层优化问题。在给定维护动作 a 的情况下，维护模型第一层的主要目的就是获得最优的备件库存策略和最小的设备资源成本，在维护模型的第二层，这个来自第一层的最小的设备资源成本作为集成动态维护模型的输入值，从而可以获得最优的设备维护策略。对于这个集成的双层动态维护模型的框架如图 5-5 所示。

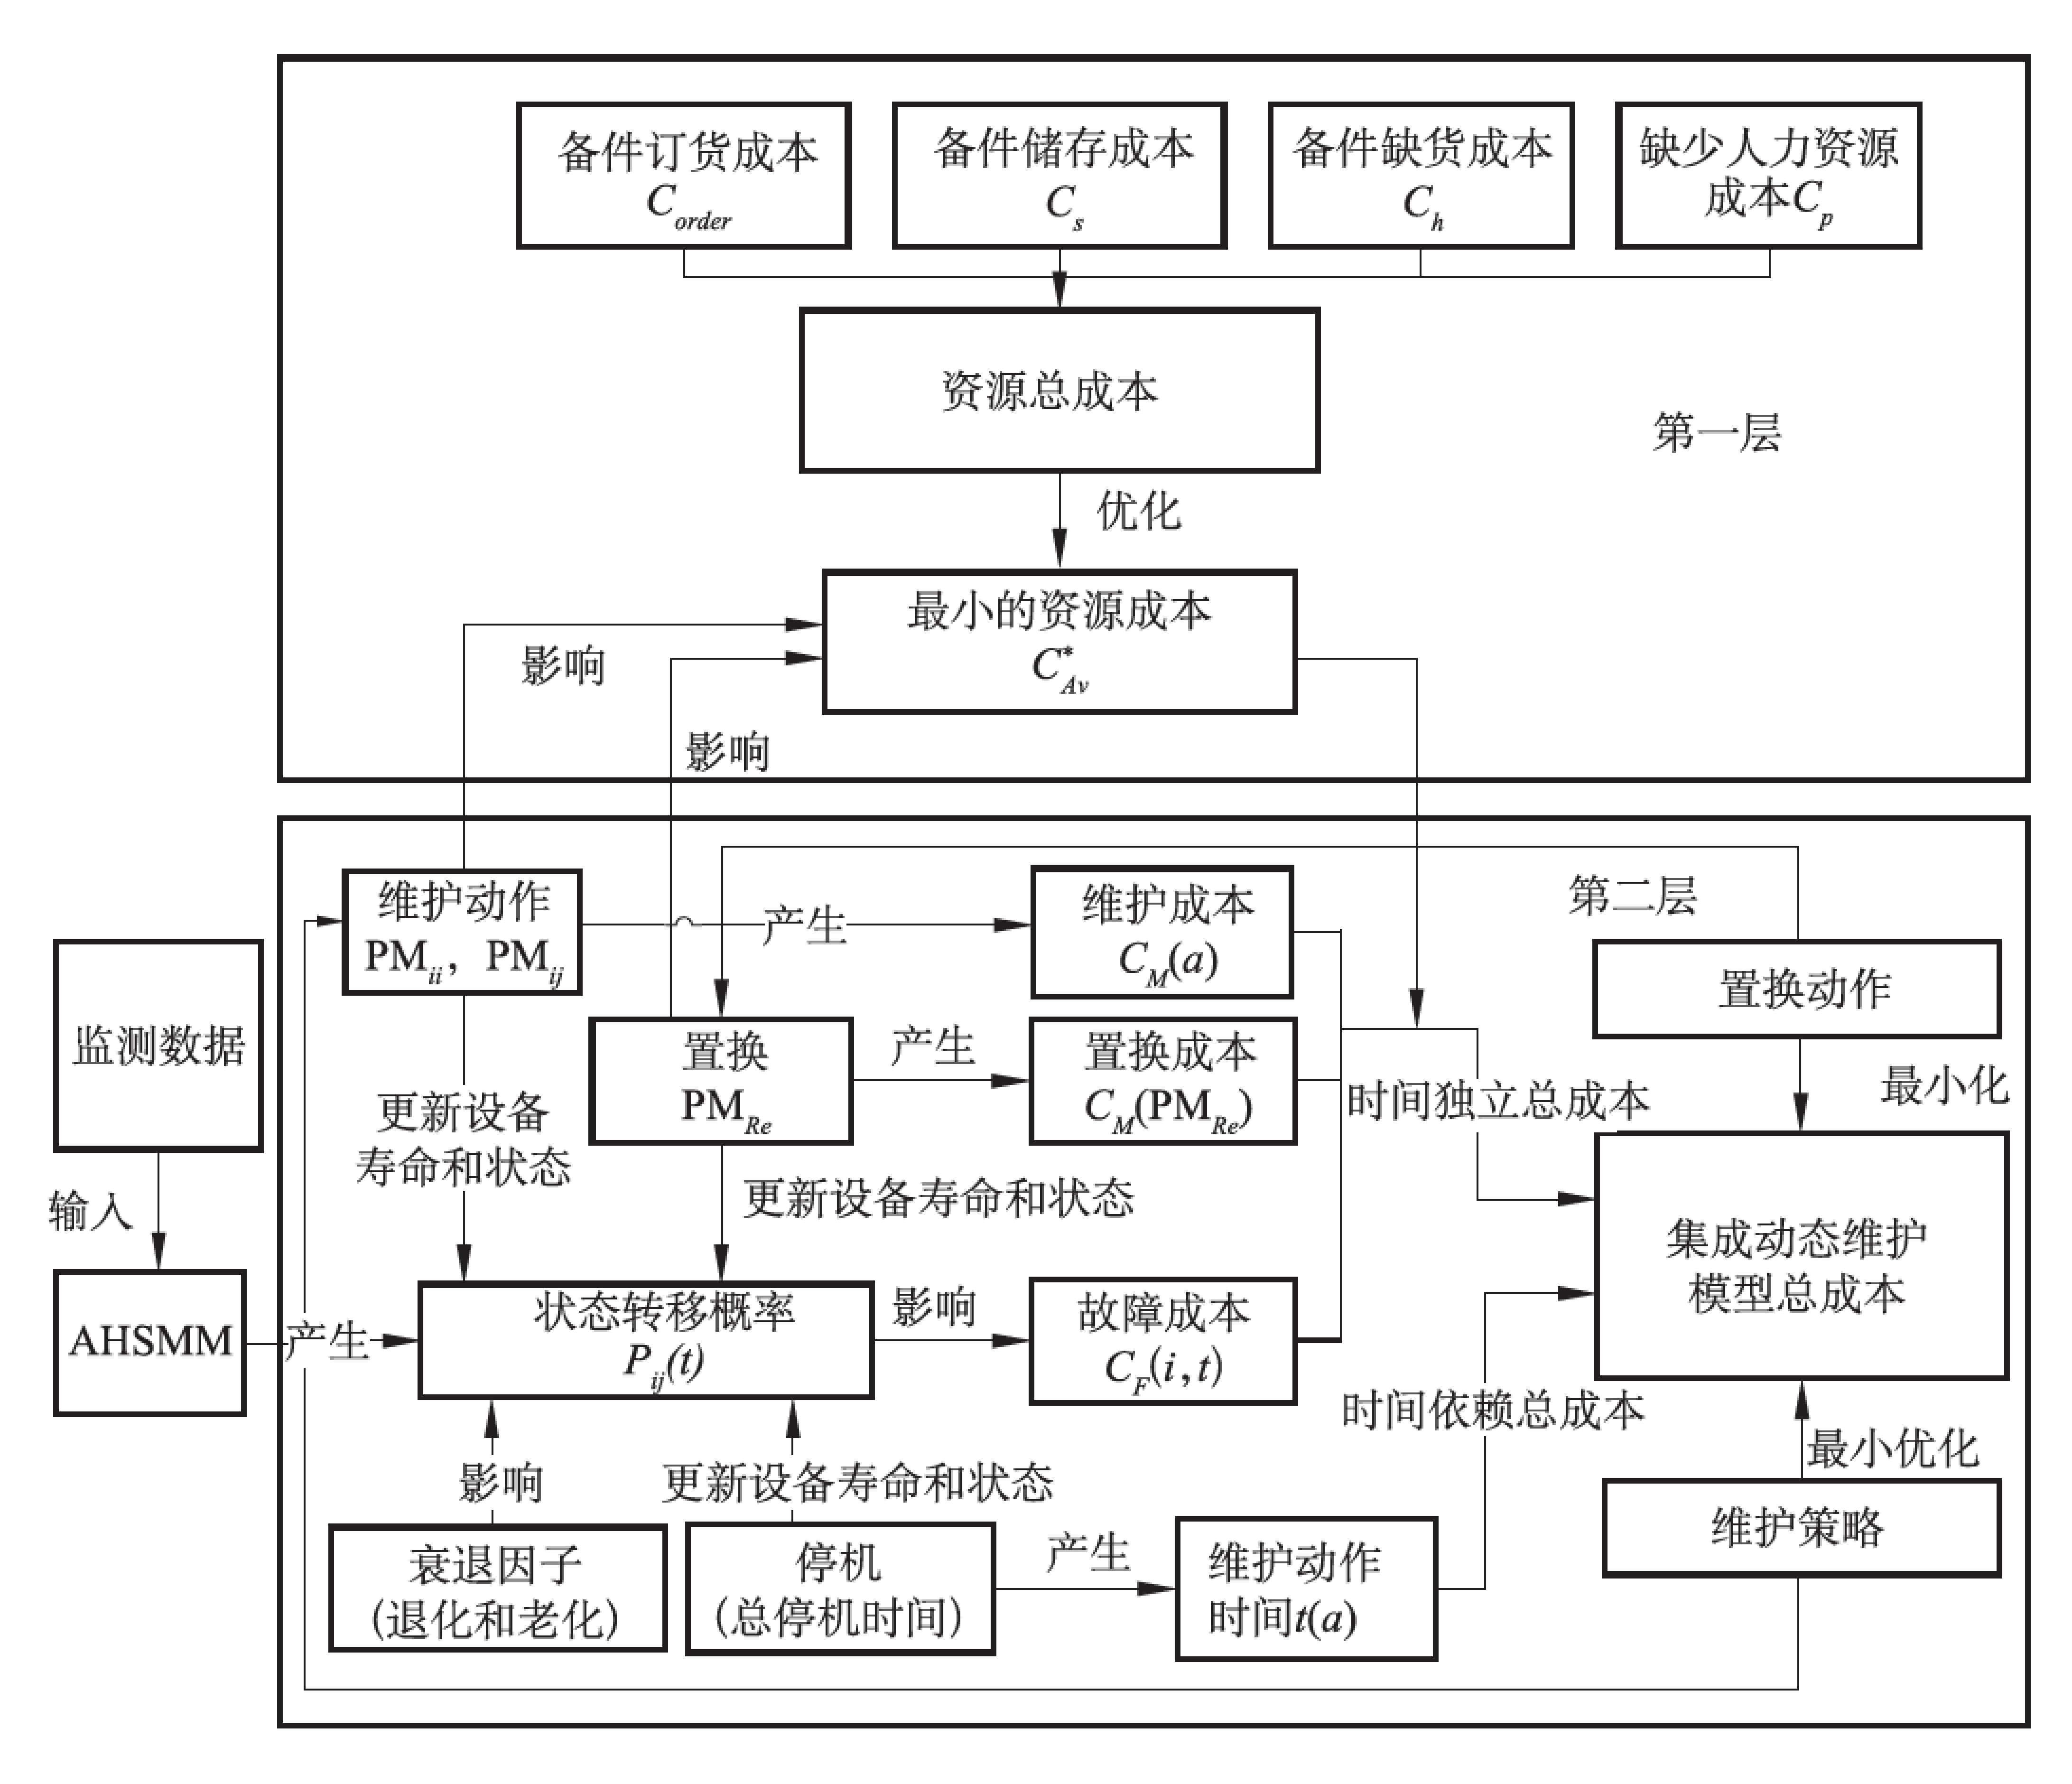


图 5-5　集成的双层动态维护模型框架

5.4.4　维护策略优化算法

基于方程(5-25)和方程(5-26)，求解提出的集成动态维护模型由两个启发式算法组成，这两个启发式算法用来求解维护模型的最优维护策略 $a(n,F-n,t_n|i)^*$ 。在第 $F-n-m$ 个维护阶段，当设备的虚龄为 t_{F-n-m} 和设备的健康为 i 时，“启发式算

法 1”被用来求解设备资源成本模型，获得最优的设备资源成本 C^*_{Av}。基于“启发式算法 1”，第 n 个维护阶段，当设备的虚龄为 t_n 和设备的健康为 i 时，“启发式算法 2”被用来求解设备的维护模型，获得设备最优的维护策略集合。两个启发式算法的详细求解步骤如下。

启发式算法 1　最优资源成本策略算法

第一步，读取参数值 $K, c_{\text{item}}, c_h, c_s, c_p, i, F$。需求集合 $r(a_n|i)$（反映了在不同状态下执行各种维修动作所需要的部件数量）。

第二步，初始化参数 $q=0$。

第三步，计算第 $F-n-q$ 个维护阶段的最优资源成本。

（1）获得最优订货数量 b_{F-n-q}。

（2）基于方程(5-25)，计算 $C_{Av}(F-q, q, a_{F-n-q}, b_{F-n-q} \mid i)$，表示为 C_{Av}。

（3）令 $b_{F-n-q}=b_{F-n-q}+1$，重新计算 $C_{Av}(F-q, q, a_{F-n-q}, b_{F-n-q} \mid i)$，表示为 C'_{Av}。

（4）比较 C_{Av} 和 C'_{Av}，如果 $C_{Av}>C'_{Av}$，则 $C'_{Av}=C_{Av}$，跳回(3)，如果 $C_{Av}<C'_{Av}$，令 $C^*_{Av}=C_{Av}$，跳至(5)。

（5）如果 $q<m$，令 $q=q+1$，跳回(1)，否则，跳至第四步。

第四步，算法结束（C^*_{Av} 是最优的资源成本）。

启发式算法 2　最优维护策略算法

第一步，读取各参数值 $C_F, C_M, t(\text{PM}), d, F$，及设备的初始状态转移概率 P_{ij}，各状态驻留时间 $t_{(k)}$。

第二步，在第 n 个维护阶段，初始化参数值 $m=0$。

第三步，计算第 $F-n-m$ 个维护阶段的最优维护动作集合。

（1）For $t_{F-m} \in \{1, 2, \cdots, t_n+F-n-m\}$

　　For $i \in \{1, 2, \cdots, L\}$

　　For $a \in \{\text{PM}_0, \text{PM}_{ii}, \text{PM}_{Re}\} \cup \{\text{PM}_{ij} \mid 1 \leqslant j \leqslant i-1, j \in H\}$

基于“启发式算法 1”，计算最优设备资源成本 C^*_{Av}

基于方程(5-25)，计算期望总系统和资源成本 $C(F-m, m, t_{F-m}, a|i)$

基于方程(5-26)，计算期望总维护时间 $T(F-m, m, t_{F-m}, a|i)$

基于方程(5-20)，计算期望总成本 $C_T(F-m, m, t_{F-m}, a|i)$

$$a(F-m,m,t_{F-m} \mid i)^* = \text{argmin}\{C_T(F-m,m,t_{F-m},a \mid i)\}$$
$$C(F-m,F-n-m,t_{F-m},a \mid i)^* = C(F-m,F-n-m,t_{F-m},a^* \mid i)$$
$$T(F-m,F-n-m,t_{F-m},a \mid i)^* = T(F-m,F-n-m,t_{F-m},a^* \mid i)$$
$$A(F-m,m,t_{F-m})^* = [a(F-m,m,t_{F-m} \mid i)^*, i=1,2,\cdots,L]$$
$$A(F-m,m)^* = [a(F-m,m \mid i,t_{F-m})^*, i=1,2,\cdots,L; t_{F-m}=1,2,\cdots,t_n+F-n-m]$$

(2) 如果 $m<F-n$，令 $m=m+1$，跳回(1)，否则，跳至第四步。

第四步，根据当前的健康状态 i 及虚龄 t_n，选择设备的最优维护动作 $a(n,F-n,t_n \mid i)^*$ 基于最优策略集合 $A(n,F-n)^*$ 。

在上述算法中，$a(F-m,m,t_{F-m} \mid i)^*$ 表示设备虚龄为 t_{F-m} 和设备的健康状态为 i 时的最优维护策略。$A(F-m,m,t_{F-m})^*$ 描述了设备虚龄为 t_{F-m} 时，所有设备健康状态的最优维护策略。$A(F-m,m)^*$ 表示了第 $F-n-m$ 个维护阶段的最优维护策略。

5.5 算例分析

在本章的案例分析中，我们仍以液压泵(设备)为研究对象。很显然，该液压泵在使用运行过程中，随着使用时间的增加性能会逐渐衰退，设备的健康状态会逐渐变差，因而，需要对设备进行相应的维护使其维持正常的工作，以避免设备失效带来的高成本和高风险。并且，随着使用运行成本和维护成本的不断增加，也可以考虑实施置换维护。因此，集成衰退性能，结合诊断信息和预测信息，在期望总成本和期望总维护时间为目标的基础上，制定集成的动态维护策略。本算例数据分析所用运行平台为 Matlab、VC，运行环境为 Windows XP。采用液压泵总计 42 组数据来描述轴承的全寿命过程。

5.5.1 数据准备

根据上面内容提出的集成动态维护模型，在使用过程中，为了制定最优的维护

策略，则所提出的集成动态维护模型的输入参数主要包括不同健康状态下的故障成本、采取各类维护动作产生的维护成本、健康状态转移概率、备件库存成本、维护人员成本等成本。

1. 状态转移概率

液压泵健康状态间的转移概率矩阵可以根据第 3 章和第 4 章的内容获得，液压泵的健康状态划分成四个健康状态：Level 1 表示正常状态；Level 2 表示衰退状态 1；Level 3 表示衰退状态 2；Level 4 表示设备失效状态。则转移概率矩阵为

$$\boldsymbol{\Phi}_t=\begin{bmatrix} 1-b'(1+\beta_2)^t\sum_{j=2}^{n}P_{1j}^0 & P_{12}^0(1+\beta_2)^t b' & K & K & P_{1F}^0(1+\beta_2)^t b' \\ 0 & 1-b'(1+\beta_2)^t\sum_{j=3}^{n}P_{2j}^0 & K & K & P_{2F}^0(1+\beta_2)^t b' \\ M & K & K & O & M \\ 0 & & K & 1-b'(1+\beta_2)^t P_{n-1,F}^0 & P_{n-1,F}^0(1+\beta_2)^t b' \\ 0 & K & K & 0 & P_{FF} \end{bmatrix}$$

t 表示设备的虚龄，β_2 表示设备的老化因子（$\beta_2=0.18$）[124]。b 是一个状态转移概率形状因子（$b'=1-b, 0\leqslant b<1$），当 b 等于 0 的时候，设备的衰退模式为递减模式。四个健康状态的初始转移概率如表 5-1 所示。不同健康状态的驻留时间如表 5-2 所示。

表 5-1　初始状态转移概率

健康状态	Level 1	Level 2	Level 3	Level 4
Level 1	0.890 3	0.108 9	0.000 6	0.000 2
Level 2	0	0.719 4	0.280 2	0.000 4
Level 3	0	0	0.981 6	0.018 4
Level 4	0	0	0	1

表 5-2　各个健康状态的期望驻留时间

健康状态	Level 1	Level 2	Level 3	Level 4
驻留均值	10.635 1	9.675 3	11.543 2	—
驻留方差	1.929 1	1.058 1	1.284 1	—
$D(h_i)$	10.700 9	9.713 3	11.585 8	—

2. 维护时间和维护成本

采取不同维护动作所产生的维护成本和维护时间如表 5-3 和表 5-4 所示。并且，设备的维护执行效用函数 $\lambda=0.6$。

表 5-3　维护动作成本

健康状态	$c_{m,i}$	$c_M(\mathrm{PM}_{iRe})$	$c_M(\mathrm{PM}_{i0})$	$c_M(\mathrm{PM}_{i1})$	$c_M(\mathrm{PM}_{i2})$	$c_M(\mathrm{PM}_{i3})$
Level 1	100	18 000	0	200	—	—
Level 2	130	18 000	0	500	250	—
Level 3	160	18 000	0	700	650	400
Level 4	190	18 000	0	—	—	—

表 5-4　维护动作时间

健康状态	$t(\mathrm{PM}_{iRe})$	$t(\mathrm{PM}_{i0})$	$t(\mathrm{PM}_{i1})$	$t(\mathrm{PM}_{i2})$	$t(\mathrm{PM}_{i3})$
Level 1	1	0	0.1	—	—
Level 2	1	0	0.5	0.15	—
Level 3	1	0	0.8	0.4	0.3
Level 4	1	0	—	—	—

3. 设备故障成本

设备的故障成本是与设备的健康状态及设备的使用时间相关联的。因此，设备的故障独立成本为

$$c_{f,i}\begin{cases}150 & i=1\\200 & i=2\\250 & i=3\\300 & i=4\end{cases}$$

设备的故障依赖成本可以表示为

$$c_o(i,t)=\begin{cases}120i+90t & i=1\\ 80i+93t & i=2\\ 70i+95t & i=3\\ \infty & i=4\end{cases}$$

4. 资源成本

设备的备件和维护人员的需求数量是由设备的健康状态与设备所采取的维护动作决定的。对于不同的维护动作所需要的设备备件和维护人员的数量如表 5-5 和表 5-6 所示。

表 5-5 设备备件需求量

健康状态	PM_{i0}	PM_{iRe}	PM_{i1}	PM_{i2}	PM_{i3}
Level 1	0	5	0	—	—
Level 2	0	5	1	0	—
Level 3	0	5	3	1	0
Level 4	0	5	—	—	—

表 5-6 设备维护人员需求量

健康状态	PM_{i0}	PM_{iRe}	PM_{i1}	PM_{i2}	PM_{i3}
Level 1	0	3	0	—	—
Level 2	0	3	1	0	—
Level 3	0	3	2	1	0
Level 4	0	3	—	—	—

其他与备件库存相关或者不相关的参数如下：

$$K=4\ 000,c_{\text{item}}=500,c_h=35,c_s=1\ 200,c_p=1\ 300,y=2,F=12,T=32$$

5. 维护动作风险

在本章中，我们用维护风险因子 r 描述设备的维护动作风险。随着 r 的增大，设备的维护动作风险也随之增大。因此，在案例中，考虑了两种维护风险，即维护风险小和维护风险大。

当维护风险小时，维护风险因子 r 可以表示为

$$r(t)=\begin{cases}0.05 & 1\leqslant t<20\\ 0.05+0.02(t-20) & 20\leqslant t<45\\ 0.5 & 45\leqslant t\end{cases}$$

当维护风险大时，维护风险因子 r 可以表示为

$$r(t)=\begin{cases}0.2 & 1\leqslant t<20\\ 0.2+0.03(t-20) & 20\leqslant t<45\\ 0.6 & 45\leqslant t\end{cases}$$

5.5.2 其他维护策略

目前，企业经常使用定期维护来维护设备的健康状态或者操作状态，因此，定期维护是一种常用的维护方式。定期维护主要包括定期维护监测和定期维修。它的目的就是在设备的生命周期内获得最优的维护策略，对于每个维护阶段，在两次维护动作之间都有一个时间间隔 T，每个时间间隔可以确定所采取的最优维护策略。

基于设备的健康状态，当设备的健康状态停留在健康状态 Level 1 时，保养性维护动作被执行，这将保持设备尽可能地停留在当前的健康状态。当设备的健康状态停留在健康状态 Level 2 或者 Level 3 时，执行维修维护动作，这将使设备从健康状态 Level 2 或者 Level 3 恢复到一个更好的健康状态。当设备的健康状态停留在健康状态 Level 4 时，执行置换维护动作，这将使设备从健康状态 Level 4 恢复到一个更好的健康状态。设定的定期维护策略如表 5-7 所示。

表 5-7　定期维护策略

健康状态	$0<t\leqslant 20$ 每 10 期维护一次 ($T=10$)	$20<t\leqslant 35$ 每 7 期维护一次 ($T=7$)	$35<t\leqslant 45$ 每 5 期维护一次 ($T=5$)	$45<t$ 每 3 期维护一次 ($T=3$)
Level 1	PM_{11}	PM_{11}	PM_{11}	PM_{11}
Level 2	PM_{21}	PM_{21}	PM_{22}	PM_{22}
Level 3	PM_{31}	PM_{32}	PM_{33}	PM_{33}
Level 4	PM_{4Re}	PM_{4Re}	PM_{4Re}	PM_{4Re}

为了模拟不同的维护情境，选择了三个主要变动参数：衰退因子 b、停机因子 d 及维护风险因子 r。每个参数选两个值，并且对这三个参数进行不同的组合来说明提出的维护模型的有效性，如表 5-8 和表 5-9 所示。

表 5-8　三个参数的取值状态

衰退	$b_1=0$（递减模式）	$b_2=0.3$（钟形模式）
停机	$d_1=1\ 000$（停机损失小）	$d_2=5\ 000$（停机损失大）
维护风险	r_1（维护风险小）	r_2（维护风险大）

表 5-9　三个参数的组合策略

组合	1	2	3	4	5	6	7	8
衰退	b_1	b_2	b_1	b_2	b_1	b_2	b_1	b_2
停机	d_1	d_1	d_2	d_2	d_1	d_1	d_2	d_2
维护风险	r_1	r_1	r_1	r_1	r_2	r_2	r_2	r_2

5.5.3　维护结果分析

对于集成动态维护策略及定期维护策略，分别执行 10 次仿真，针对每次仿真，每种维护策略都包括 600 个检测周期，根据 10 次仿真的平均值来计算仿真评价指标。单位平均成本 c，设备平均寿命 t 被用作仿真评价指标，两种策略的仿真结果如表 5-10 所示。

从表 5-10 的 8 种组合策略可以看出，在单位时间成本降低的方面，集成的动态维护策略都具有良好的表现，具有比定期维护策略更好的性能。对于集成的动态维护的所有组合策略，组合策略 1 是最好的，由于集成的动态维护策略积极的维护动作，设备处于较好状态的持续工作时间要长于定期维护策略。因此，采取集成的动态维护策略的设备平均寿命周期要长于定期维护策略。

表 5-10　两种维护策略的不同组合策略的仿真结果比较

组合策略	组合 1		组合 2	
维护策略	集成动态维护策略	定期维护策略	集成动态维护策略	定期维护策略
c	1 351.87	1 751.49	1 522.37	1 938.31
t	64.38	52.19	52.87	44.62
成本降低	399.62(22.81%)		415.94(21.45%)	
寿命延长	12.19(23.35%)		8.25(18.48)	
组合策略	组合 3		组合 4	
维护策略	集成动态维护策略	定期维护策略	集成动态维护策略	定期维护策略
c	1 765.43	2 191.07	1 923.73	2 262.7
t	60.26	51.79	53.52	45.87
成本降低	425.64(19.42%)		338.97(14.98%)	
寿命延长	8.47(16.35%)		7.65(16.67%)	

续表

组合策略	组合 5		组合 6	
维护策略	集成动态维护策略	定期维护策略	集成动态维护策略	定期维护策略
c	1 503.64	1 943.95	1 603.95	1 951.78
t	55.97	46.36	50.77	43.57
成本降低	440.31(22.65%)		347.83(17.82%)	
寿命延长	9.61(20.72%)		7.2(16.53%)	
组合策略	组合 7		组合 8	
维护策略	集成动态维护策略	定期维护策略	集成动态维护策略	定期维护策略
c	1 889.16	2 168.97	1 980.41	2 277.93
t	58.92	50.53	48.94	42.76
成本降低	279.81(12.9%)		297.52(13.06%)	
寿命延长	8.39(16.61%)		6.18(14.45%)	

对于设备总体集成动态维护策略，如表 5-11 所示，通过采取定期设备维护策略延长了设备的寿命，但是，设备的维护占用了较长的设备工作时间，使设备长时间处于停机状态，进而损耗了高昂的设备维护成本。采用集成动态维护策略的目标不仅仅是增加设备的平均寿命，而且可以基于设备的健康状态，选择最优的维护策略，进而提高设备的利用率，延长设备的平均寿命，降低设备维护的单位成本。从表 5-11 的计算数据可以看出，集成动态维护策略与不维护相比较，采用集成动态维护策略可以降低设备的单位维护成本 26.91%，提高设备的利用率 1.39%。与定期维护相比较，采用集成动态维护策略降低单位维护成本 17.88%，提高设备的利用率 5.91%。与没有考虑资源等约束条件的纯动态维护策略相比较，采用集成动态维护策略可以降低单位维护成本 8.6%，提高设备的利用率 3.6%。

表 5-11　不同维护策略的仿真比较结果

评估标准	集成动态维护策略	纯动态维护策略	定期维护	不维护
c	1 692.57	1 851.86	2 060.78	2 318.53
t	55.71	51.69	47.21	32.69
Au(%)	98.85	95.29	91.28	95.42

图 5-6 描述了定期维护在某一次全寿命过程中采取的维护动作。其中，x 坐标代表了设备的寿命，y 坐标代表执行的维护动作，0 表示 PM_0，1 表示 PM_{11}，2 表示 PM_{21}，3 表示 PM_{22}，4 表示 PM_{31}，5 表示 PM_{32}，6 表示 PM_{33}，7 表示 PM_{Re}。根据图 5-6，在定期维护的情形下，当健康状况转移到 Level 6 时，设备的寿命为 45，这种情况下，仍然对设备执行了大量的维护动作，提高了设备的运转时间，增加了设备的寿命。然而，采取这些维护动作花费了大量的维护时间及费用。

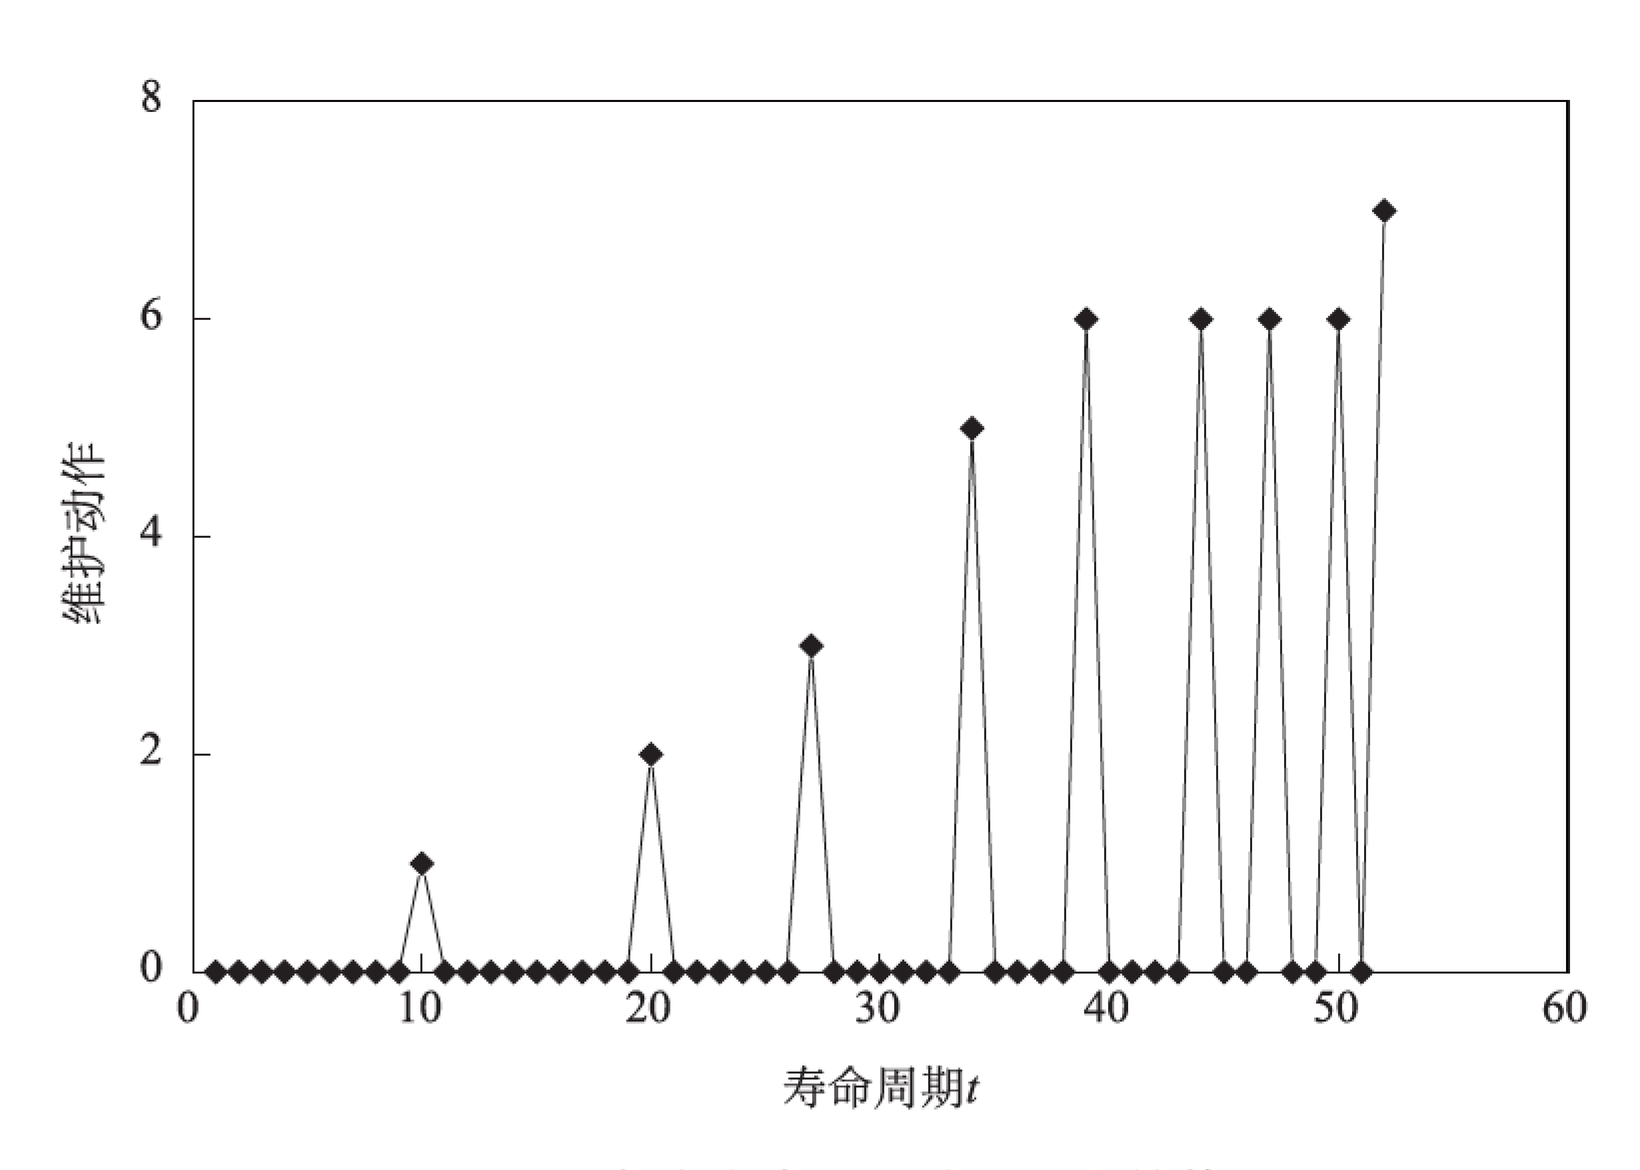


图 5-6　设备全寿命周期的定期维护策略

图 5-7 描述了集成动态维护在某一次全生命过程中采取的维护动作。从图 5-7 中可以看出，在设备的初始工作状态，集成动态维护策略执行了大量的保养维护和维修维护，在这种情况下，设备可以较长时间地维持在比较好的设备健康状态，从而减少设备的故障成本。在设备持续工作过程中，在设备转移到健康状态 Level 3 后，即使对设备采取维护动作 PM_{31}，使设备从健康状态 Level 3 恢复到健康状态 Level 1，设备在后续的运转过程，也很快会转移到健康状态 Level 3。从图 5-7 中的曲线可以看出，当设备进入健康状态 Level 3 后，对设备来说，并没执行大量的维护动作，置换维护动作被执行，设备就可以恢复到一个较好的健康状态。

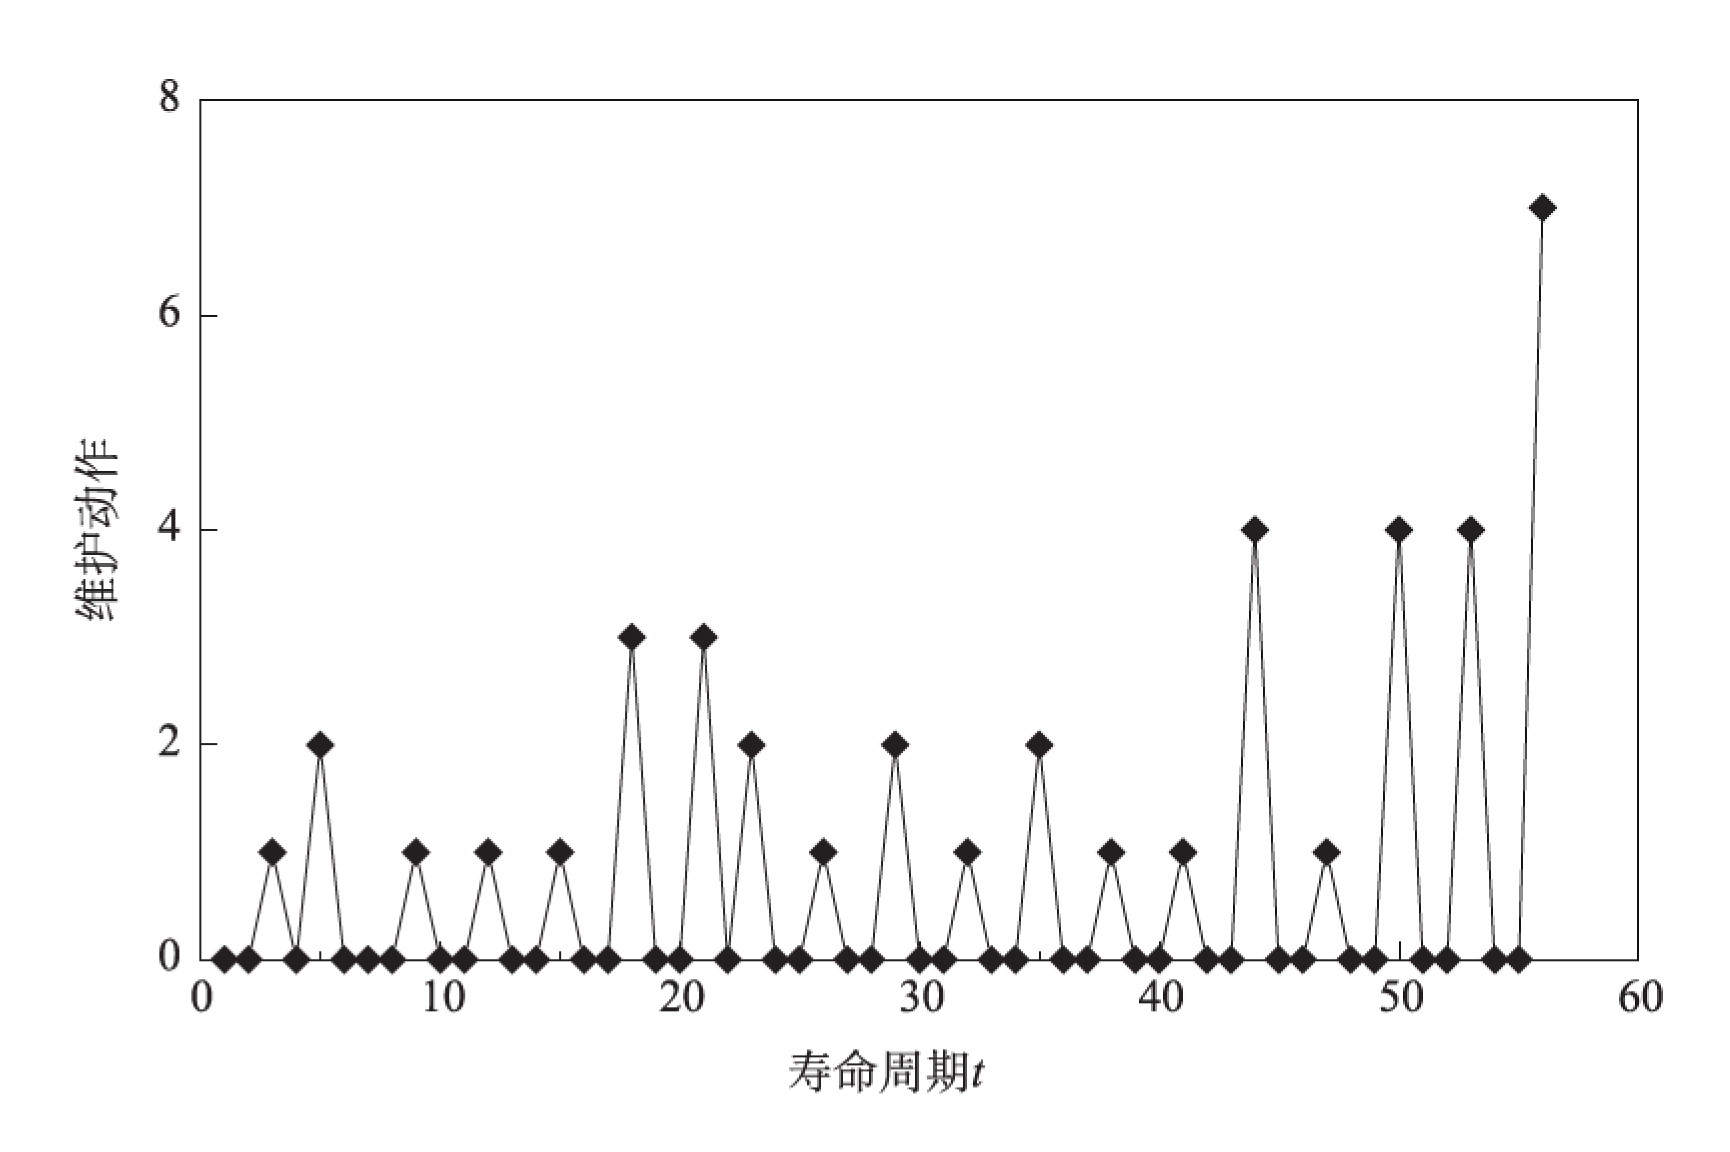


图 5-7　设备全寿命周期的集成动态维护策略

5.5.4　备件库存策略分析

在这一部分,将对设备全寿命周期的集成动态维护策略和备件库存水平之间的关系进行分析,图 5-8 显示了设备在集成动态维护策略和备件库存水平之间的关系。从图 5-8 中可以看出,由于高昂的备件订货费用,当设备进入健康状态 Level 2 时,为了使设备的健康状态从 Level 2 恢复到 Level 1,最优的集成动态维护没有选择执行 PM_{21}。随着运转时间的增长,设备的故障成本会相应地提高,在这种情况下,将设备备件的订货费用,在后续的设备备件需求过程中,逐次进行分摊。执行维护动作 PM_{21} 和 PM_{31},确定订货决策。

当固定订货费用等于 0 时(即 $K=0$),图 5-9 表示了最优集成动态维护的变化趋势。如果没有固定的备件订货费用,最优的备件库存策略就是按需求订货,没有备件的库存,但是,相对应的最优维护策略会发生改变。设备状态转移到 Level 2,需要立即执行 PM_{21},从而确保设备长时间地保持正常工作。并且,最优集成动态维护策略在不同的备件库存参数下,会发生相对应的变化。如果说在集成动态维护策略模型中,没有集成备件的信息,设备的维护不受备件订货、库存及缺货的影响,但是,在获得最优的设备维护策略的同时,造成了极高的设备备件费用。

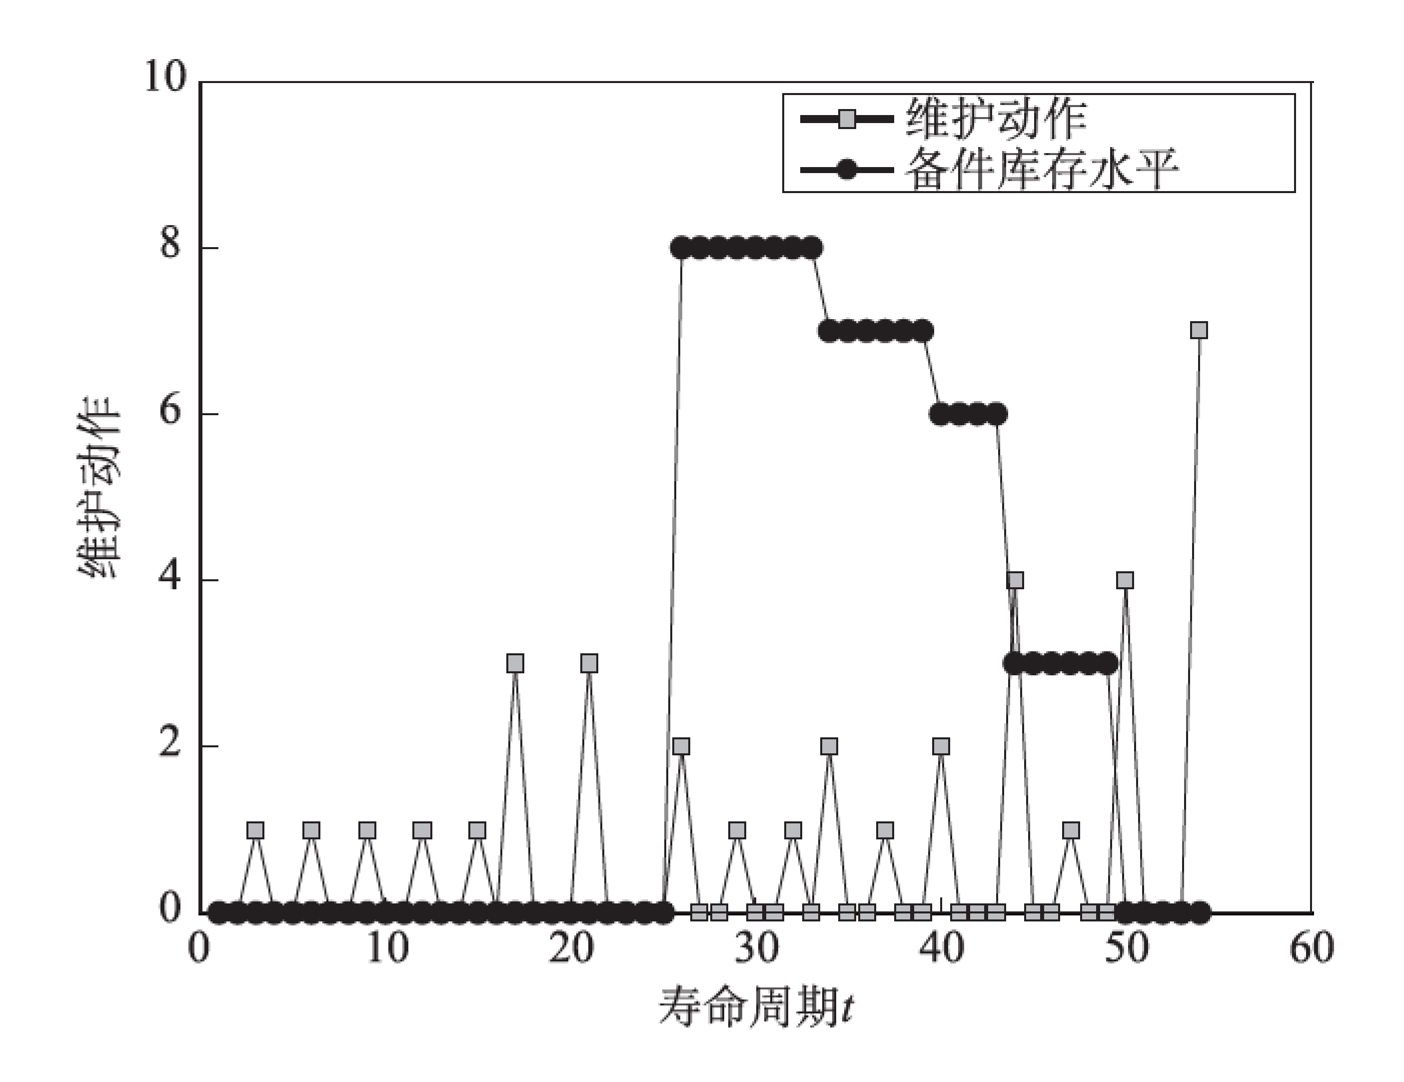


图 5-8　集成动态维护策略与备件库存水平之间的关系

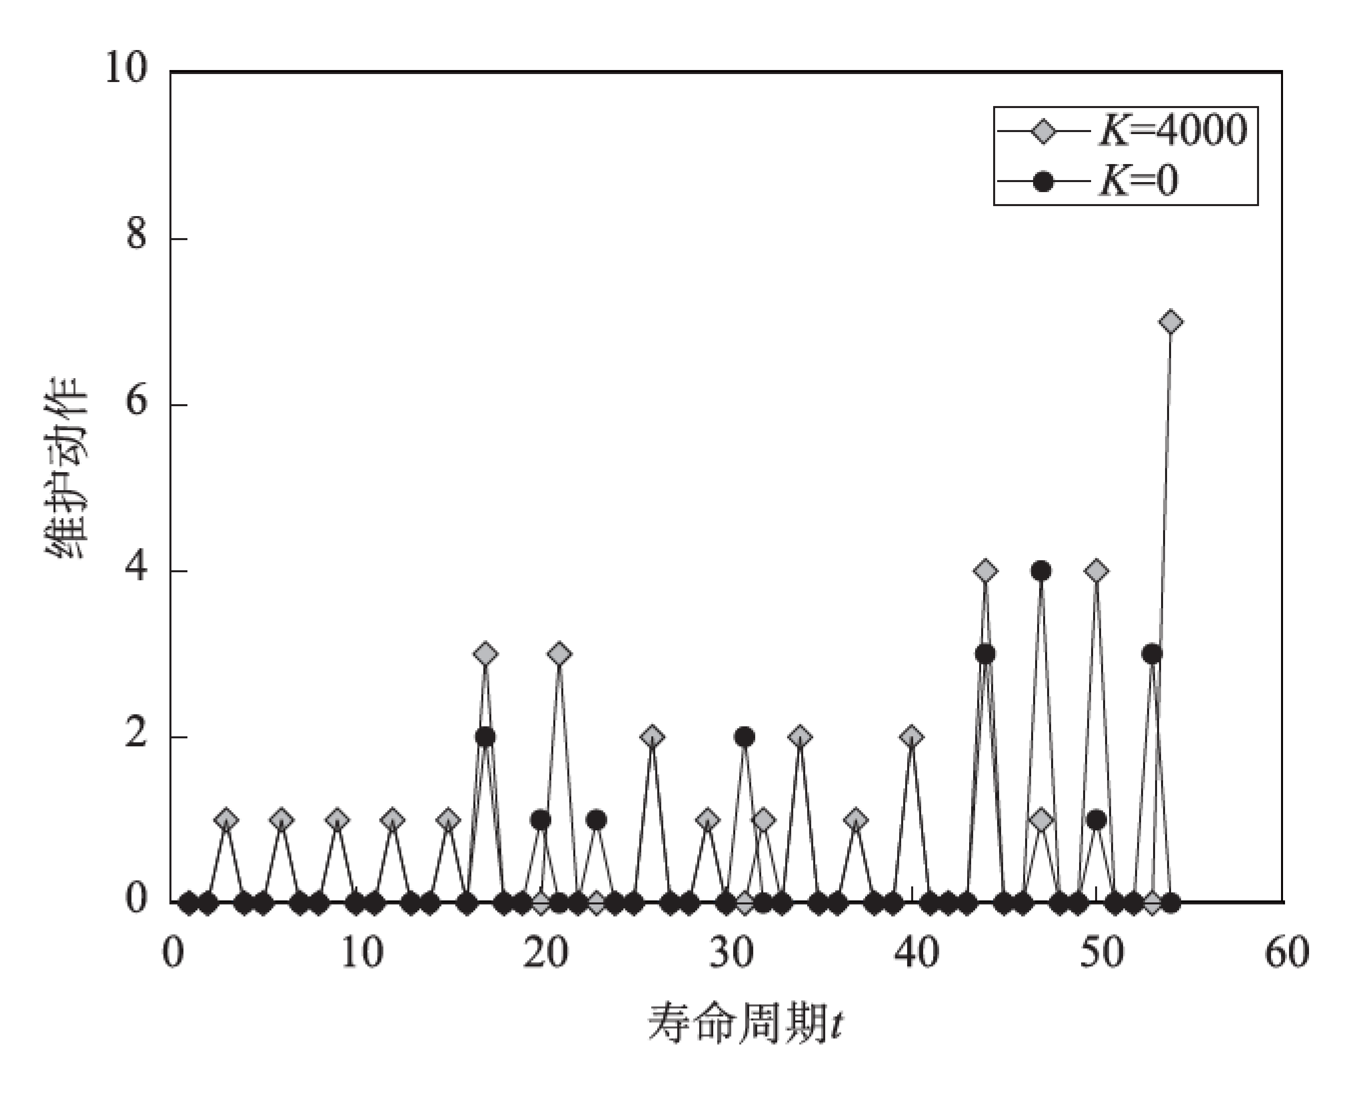


图 5-9　固定订货费用对最优维护策略的影响

5.5.5　策略动态性分析

在制定集成动态维护策略过程中，有三个参数对集成动态维护策略的制定有影响，分别是转移概率形状因子 b、停机因子 d 和维护风险因子 r。

1. 设备衰退对集成动态维护策略决策的影响

对组合策略 1 和组合策略 2 来说，具有相同的停机因子和维护风险因子，但是

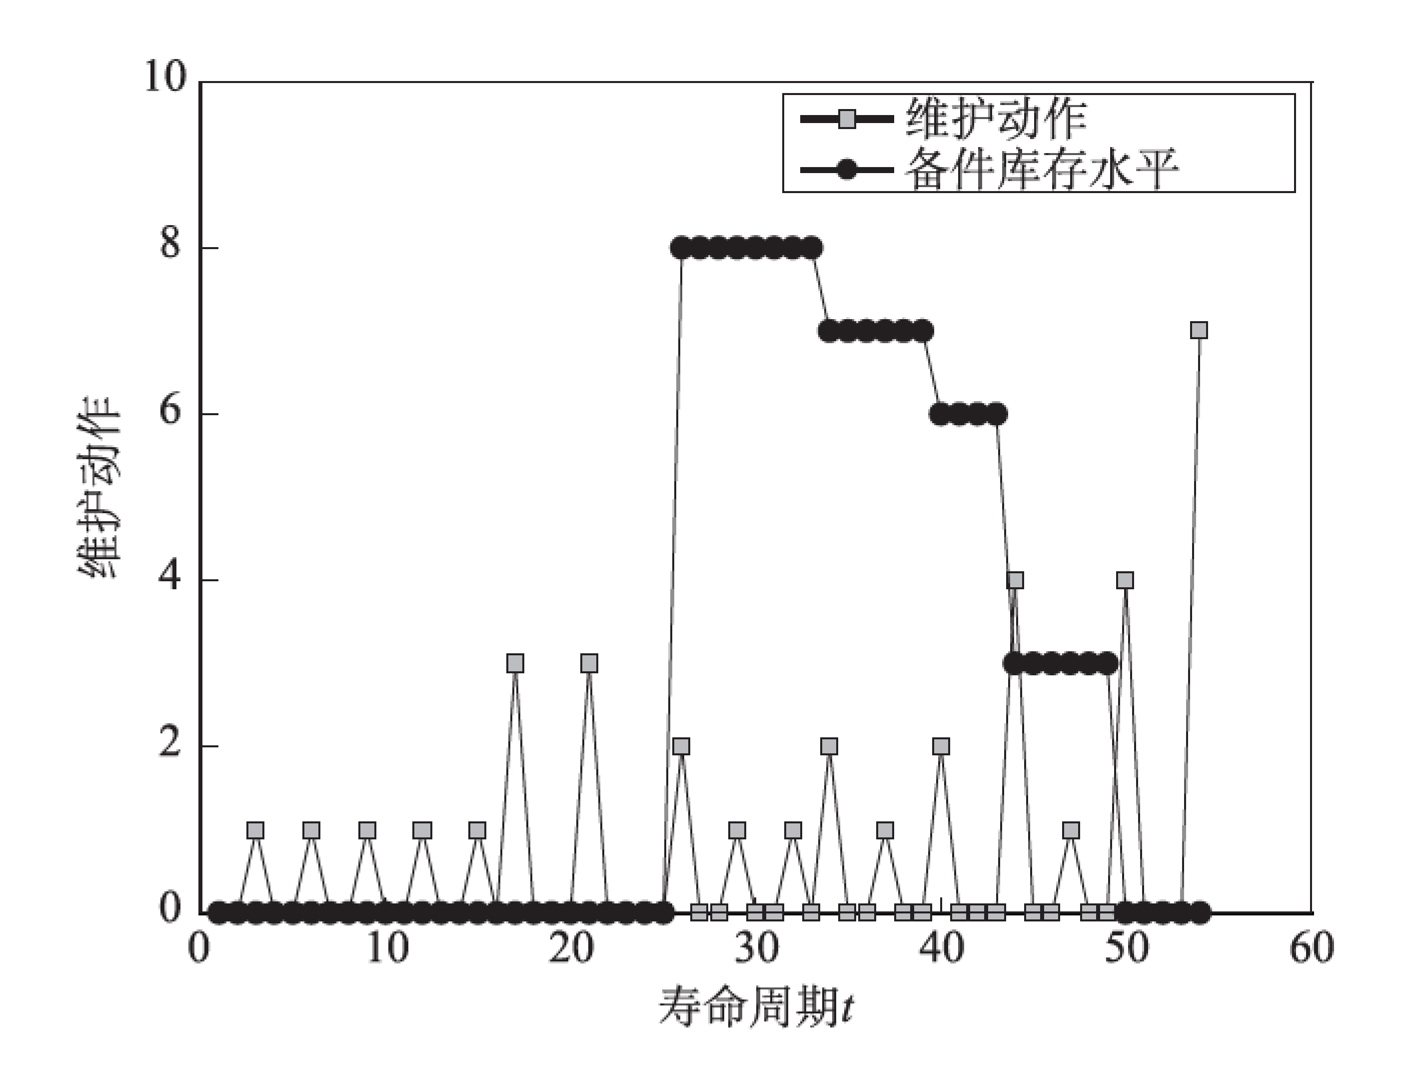


图 5-8　集成动态维护策略与备件库存水平之间的关系

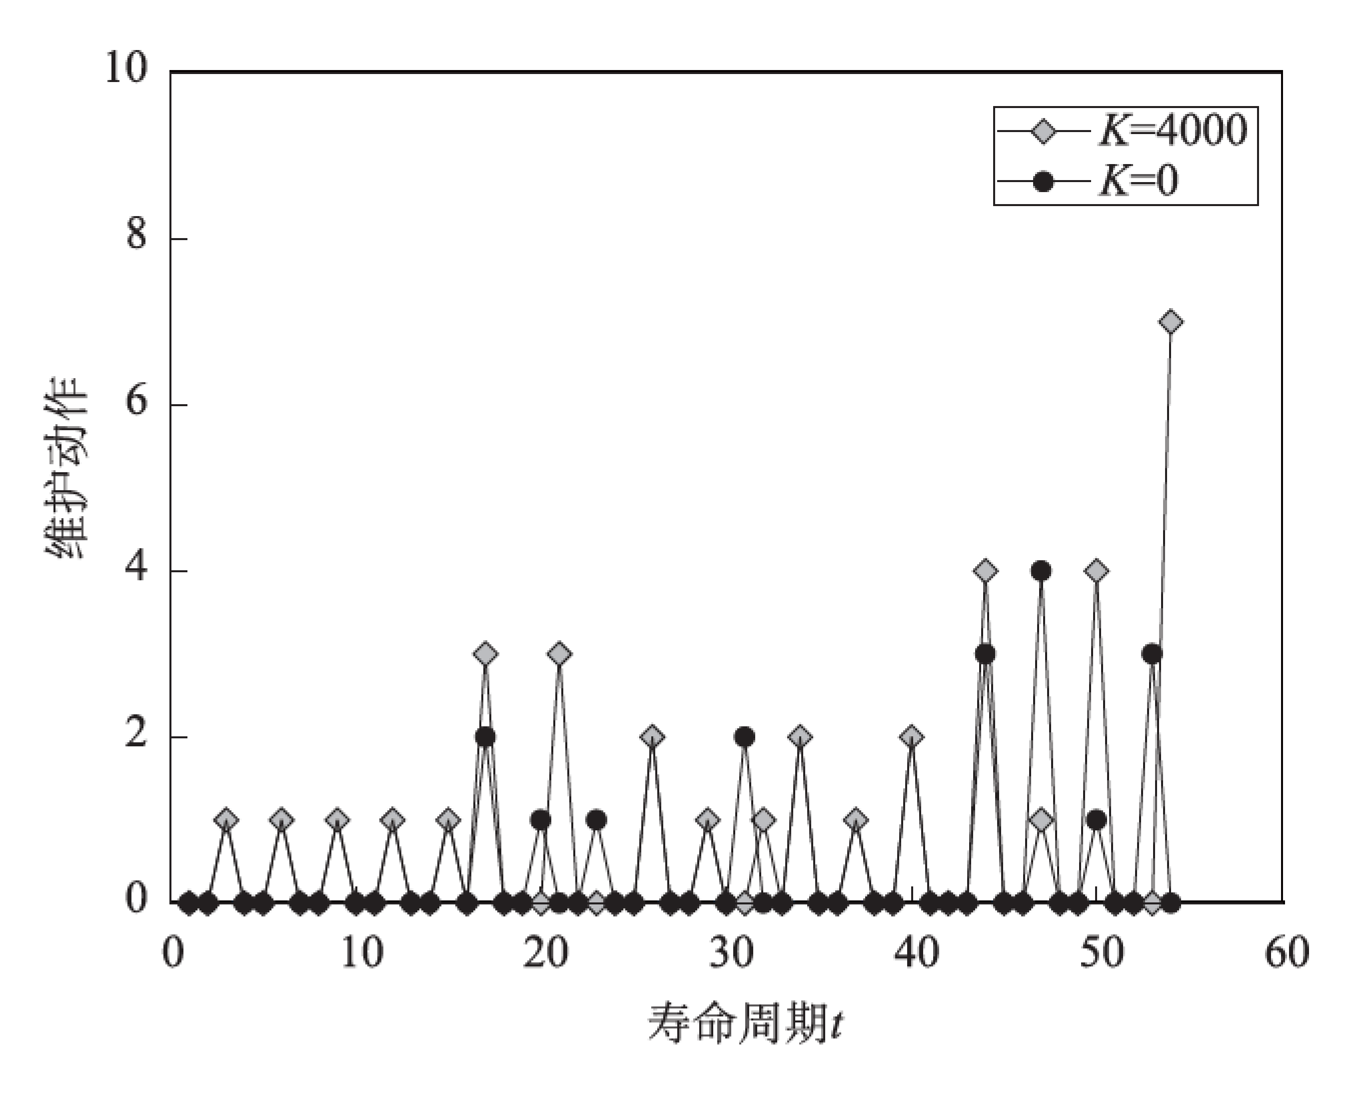


图 5-9　固定订货费用对最优维护策略的影响

5.5.5　策略动态性分析

在制定集成动态维护策略过程中，有三个参数对集成动态维护策略的制定有影响，分别是转移概率形状因子 b、停机因子 d 和维护风险因子 r。

1. 设备衰退对集成动态维护策略决策的影响

对组合策略 1 和组合策略 2 来说，具有相同的停机因子和维护风险因子，但是

设备的衰退模式不同，对应不同的衰退因子 b，所获得的集成动态维护动作决策如图 5-10 所示。

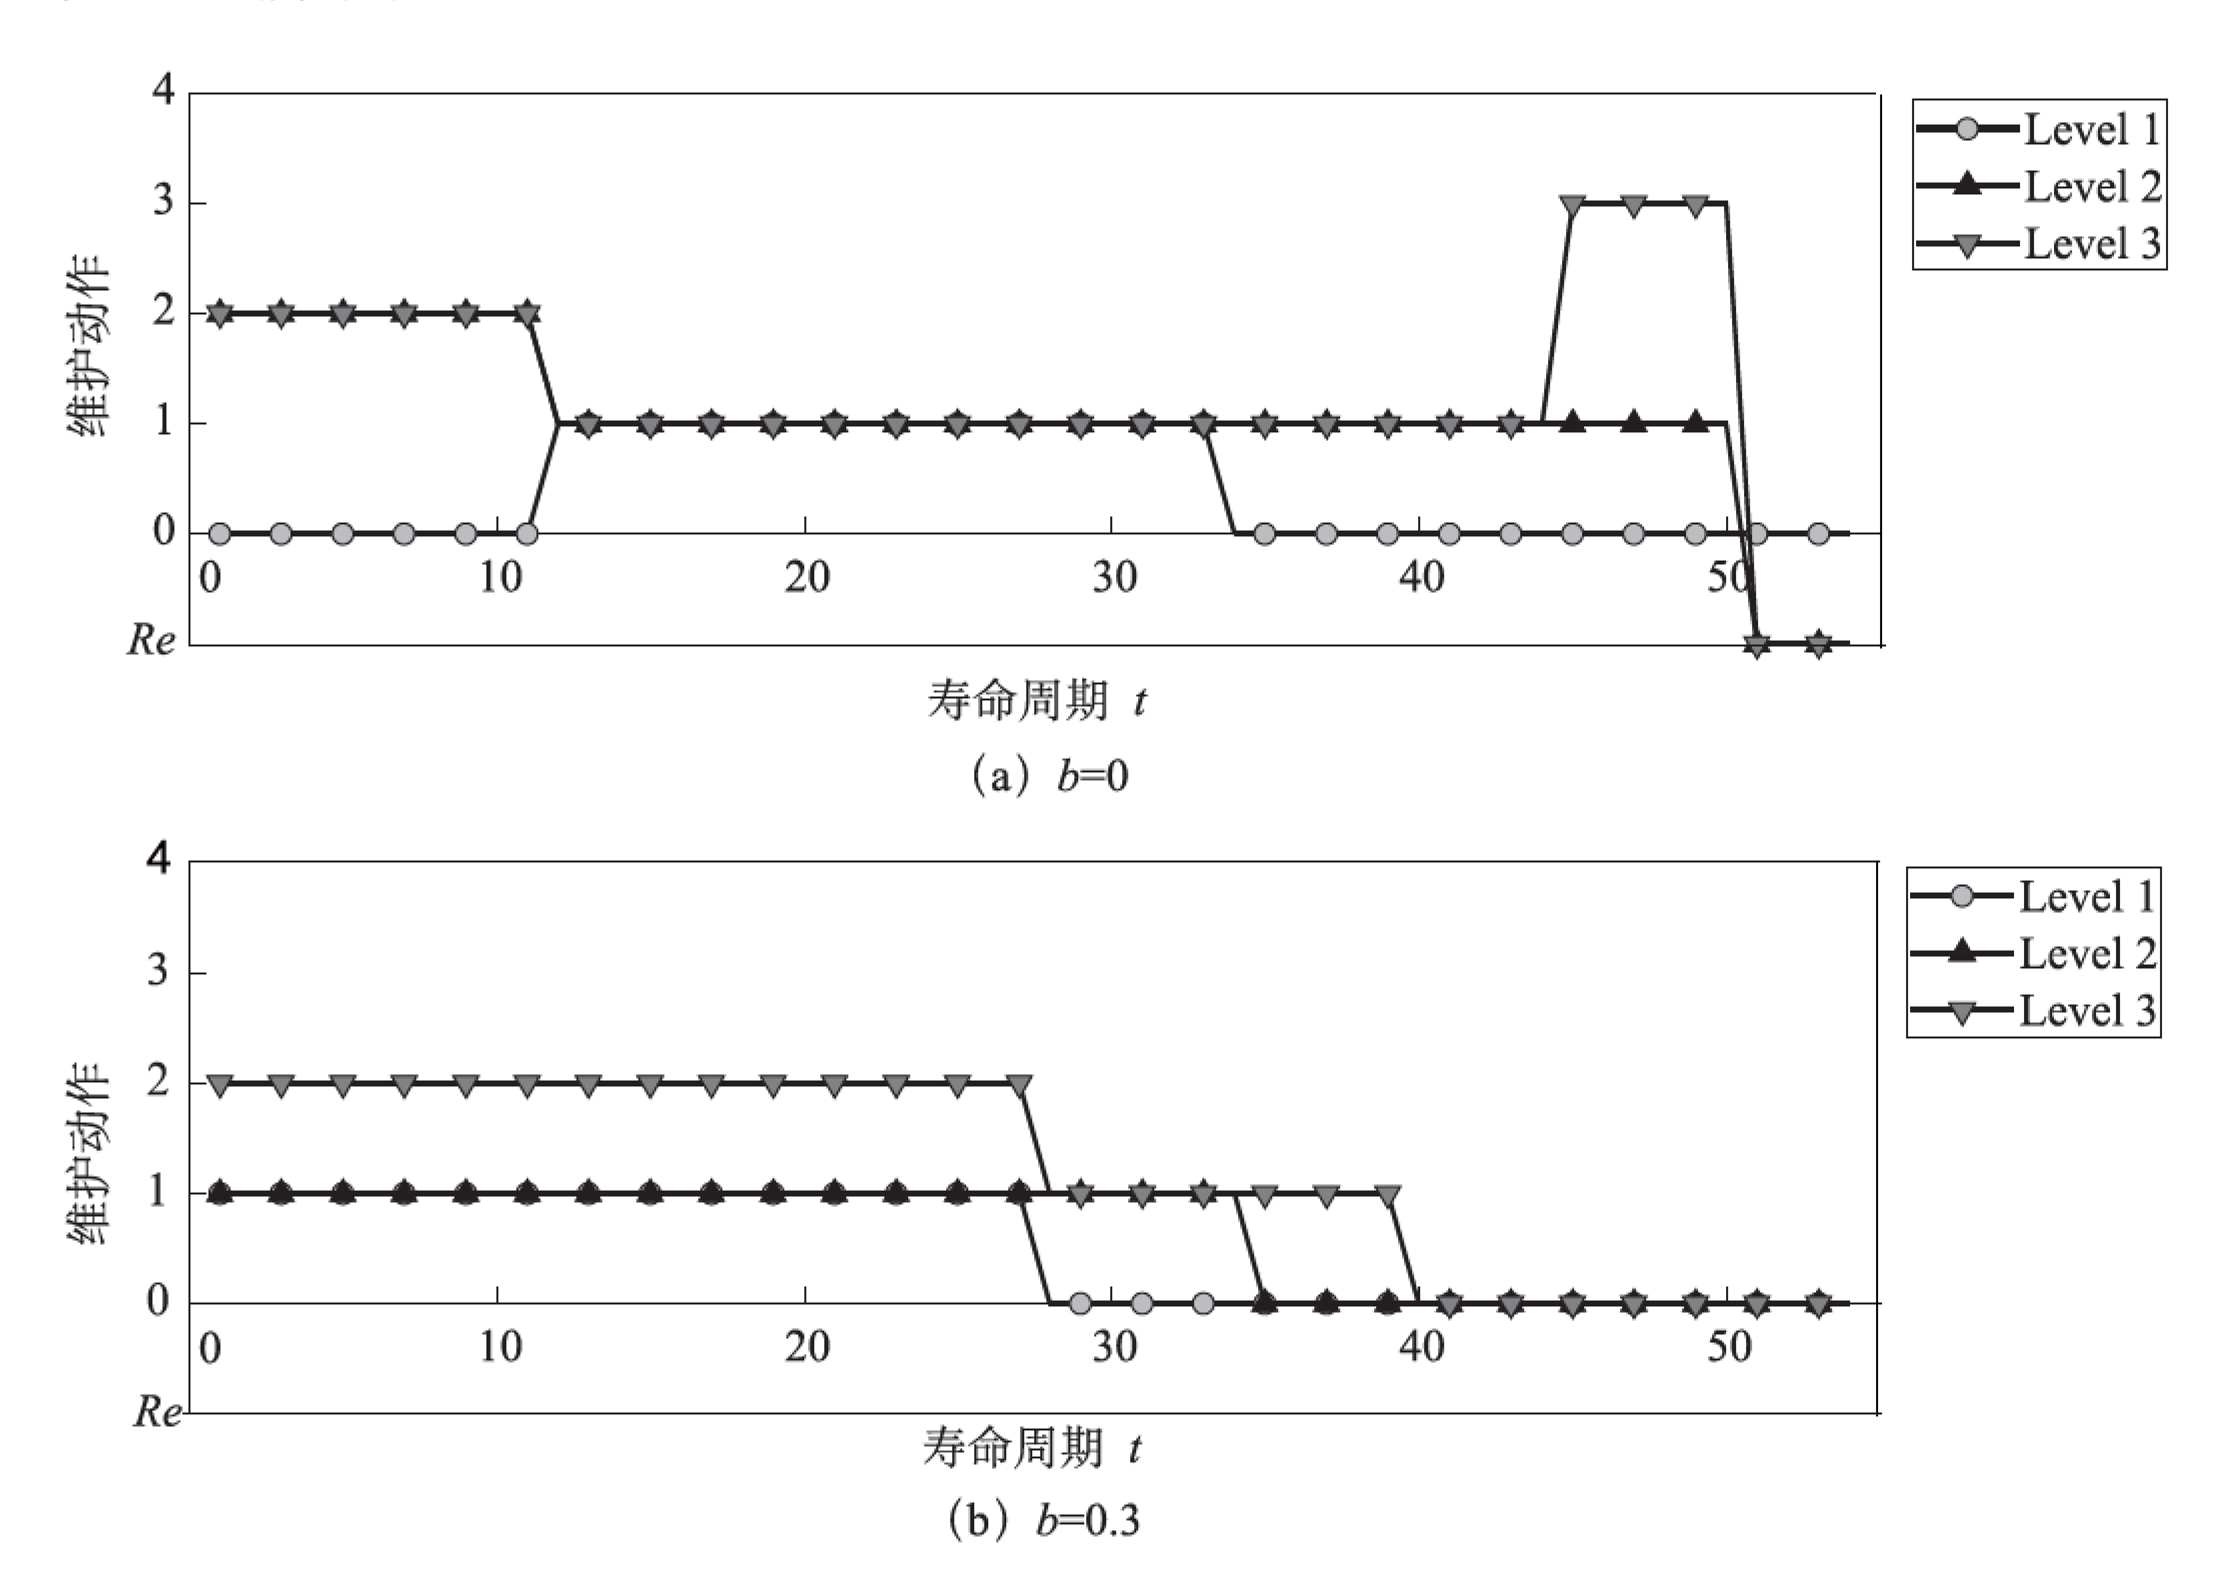


图 5-10　衰退因子大小对应的维护动作

随着衰退因子 b 的增加，设备的衰退模式将逐渐从递减模式向钟形模式转移。在递减模式下，设备以最大的概率停留在当前的健康状态，在钟形模式下，设备保持在当前健康状态的概率变小，设备更加倾向于向较差的状态转移。因此，置换维护动作将被执行，降低设备的老化速度。对应不同的衰退模式，将产生不同的维护策略，从图 5-10 中可以看出，为了适应不同的衰退模式，集成动态维护策略可以自动进行调整，以保持设备的正常使用。

2. 设备停机对集成动态维护策略决策的影响

对组合策略 1 和组合策略 3 来说，具有相同的衰退趋势和维护风险因子，但是设备的停机损失不同，对应不同的停机因子 d，所获得的集成动态维护动作决策如图 5-11 所示。

根据停机因子 d 取不同的值，设备具有不同的利用率和停机损失。与其他维护动作相比较，置换维护动作需要一个比较长的维护时间，在这种情况下，造成很

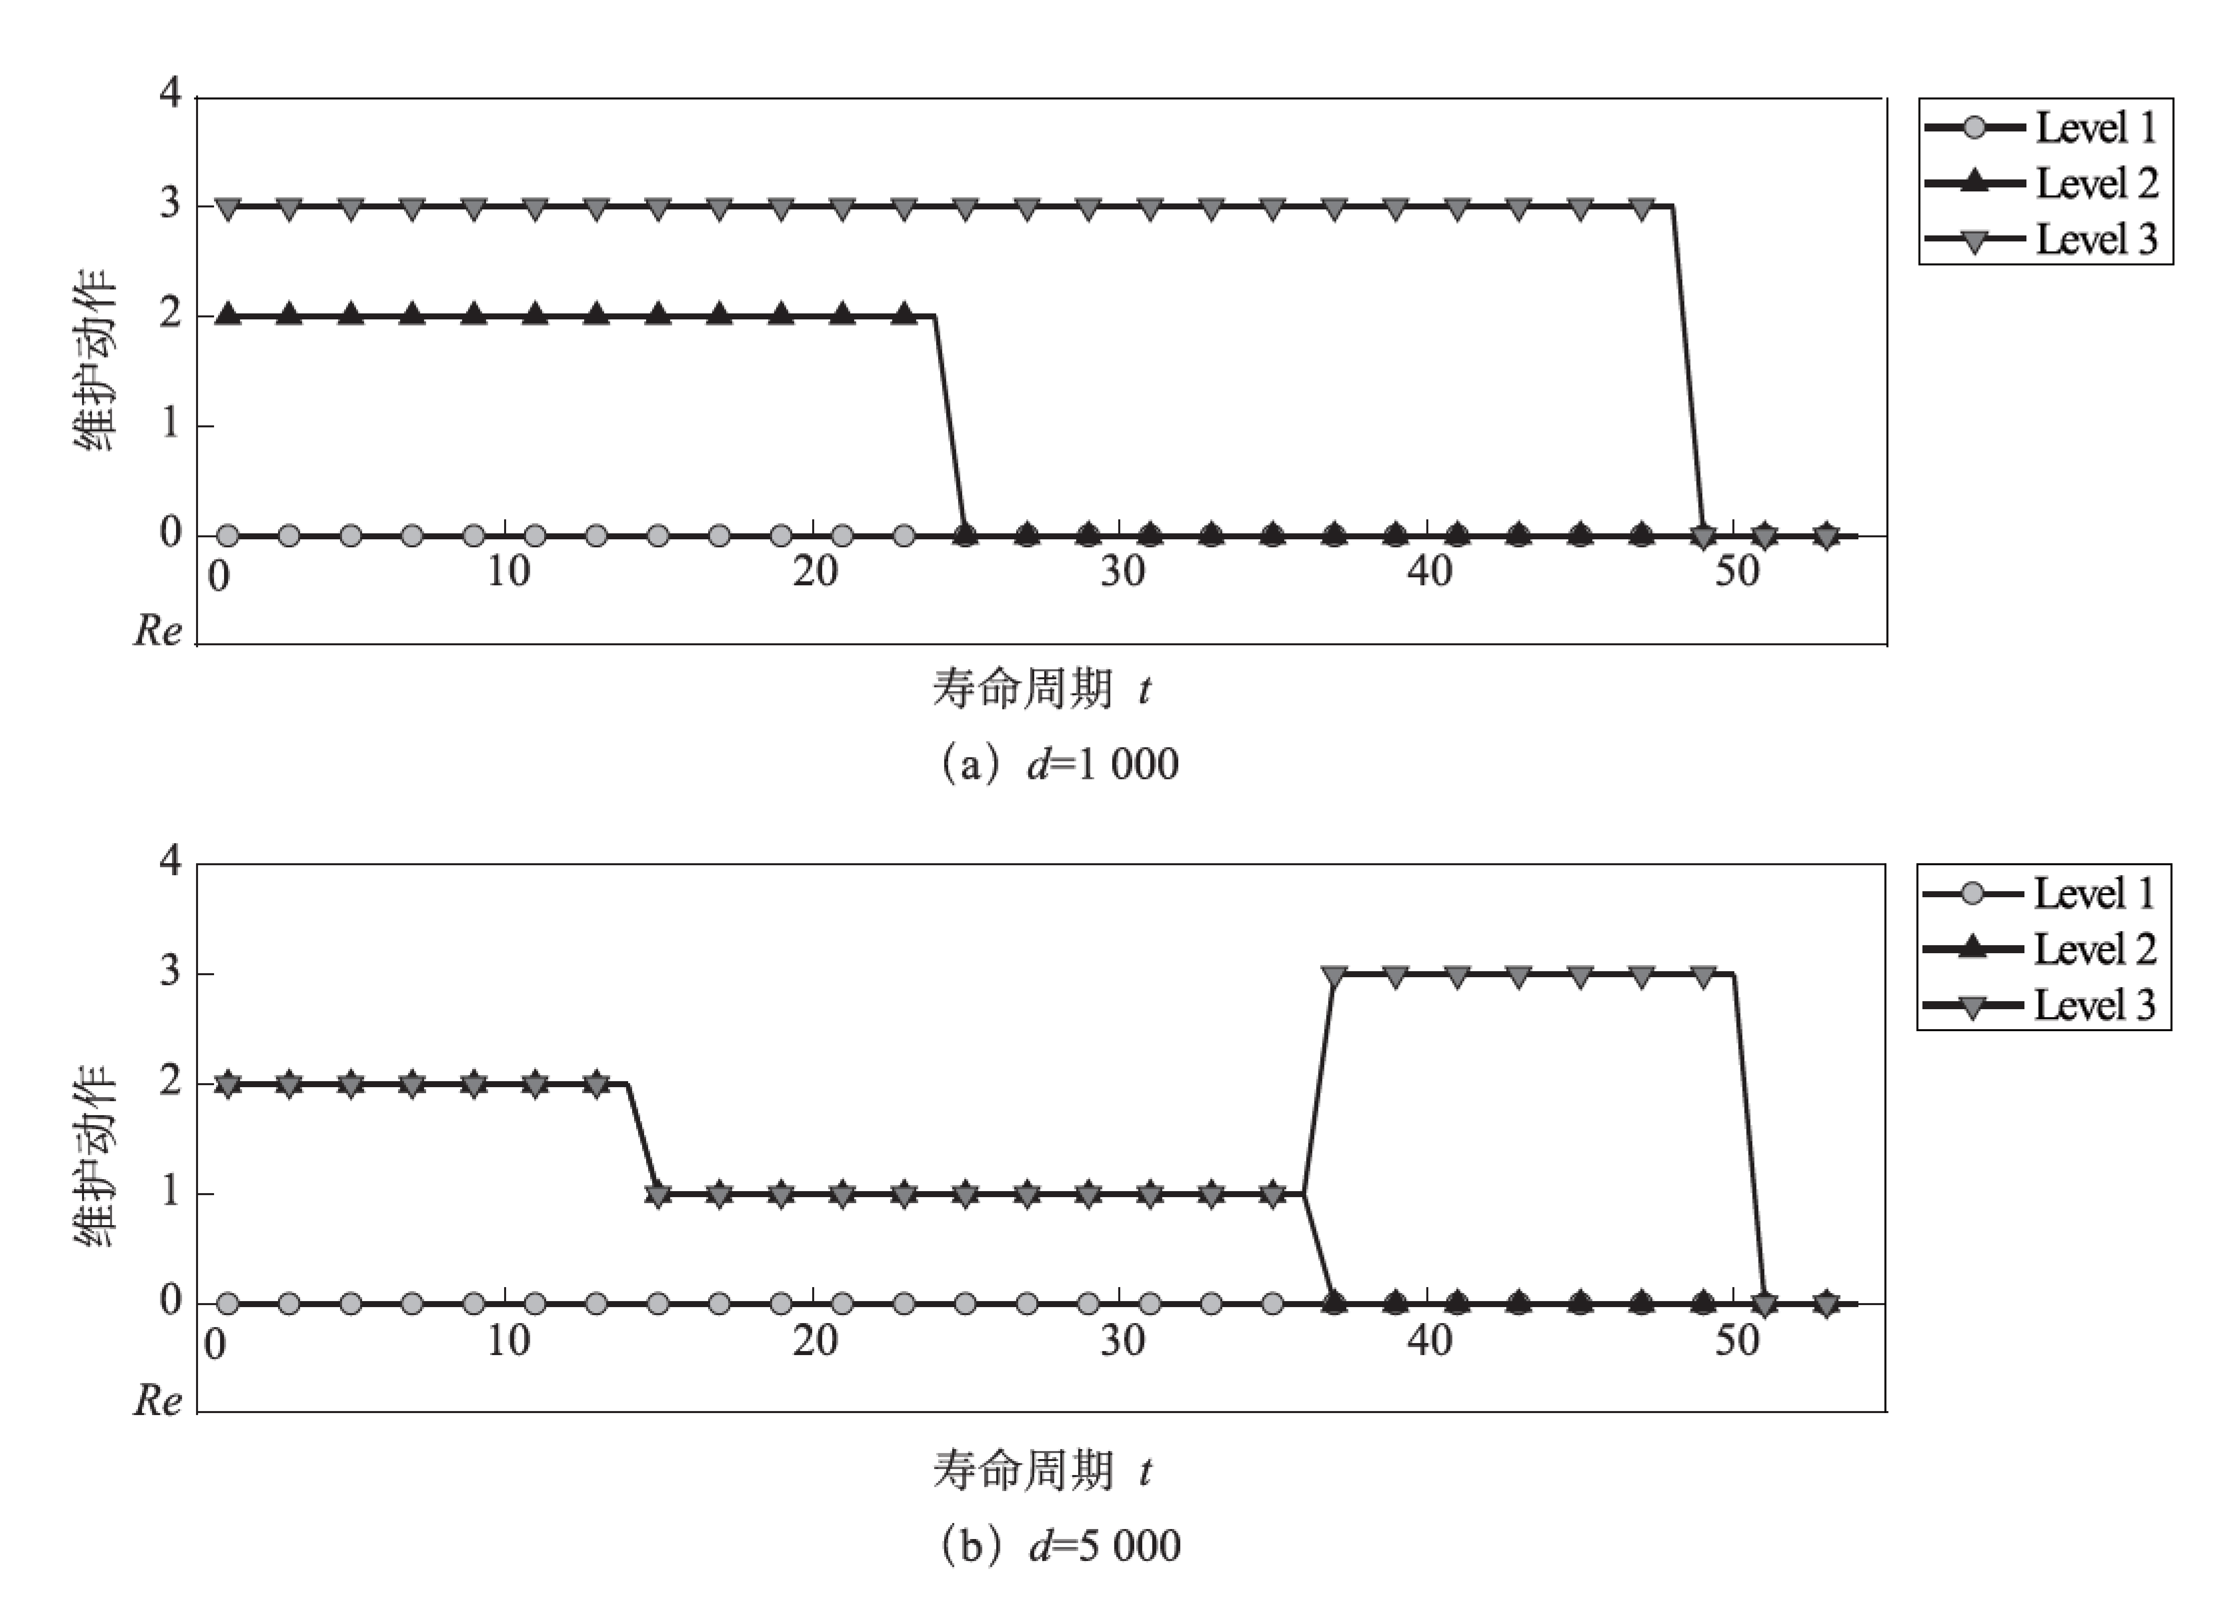


图 5-11　停机损失因子大小对应的维护动作

大的设备停机损失。从图 5-11 中可以看出，随着停机因子 d 的增加，为了降低设备置换维护的次数和避免设备的健康状态转移到更差的状态，将对设备采取大量的保养维护和维修维护动作。

3. 设备维护风险对集成动态维护策略决策的影响

除了不维护和置换维护动作，其他的维护动作在执行过程中，都会产生一定程度的维护风险。随着设备维护风险的增加，对设备实际的维护效果会离期望维护目标越来越远。对组合策略 1 和组合策略 5 来说，具有相同的衰退趋势和停机因子，但是设备的维护风险损失不同，对应不同的维护风险因子 r，所获得的集成动态维护动作决策如图 5-12 所示。

随着维护风险因子 r 的增加，为了弥补由于采取维护动作所产生的维护风险，设备需要去增大维护动作的改善幅度，即转换维护动作的方式。从图 5-12 中可以看出，针对不同的维护风险，集成的动态维护策略能调整维护动作，保持设备处于较好的健康状态。

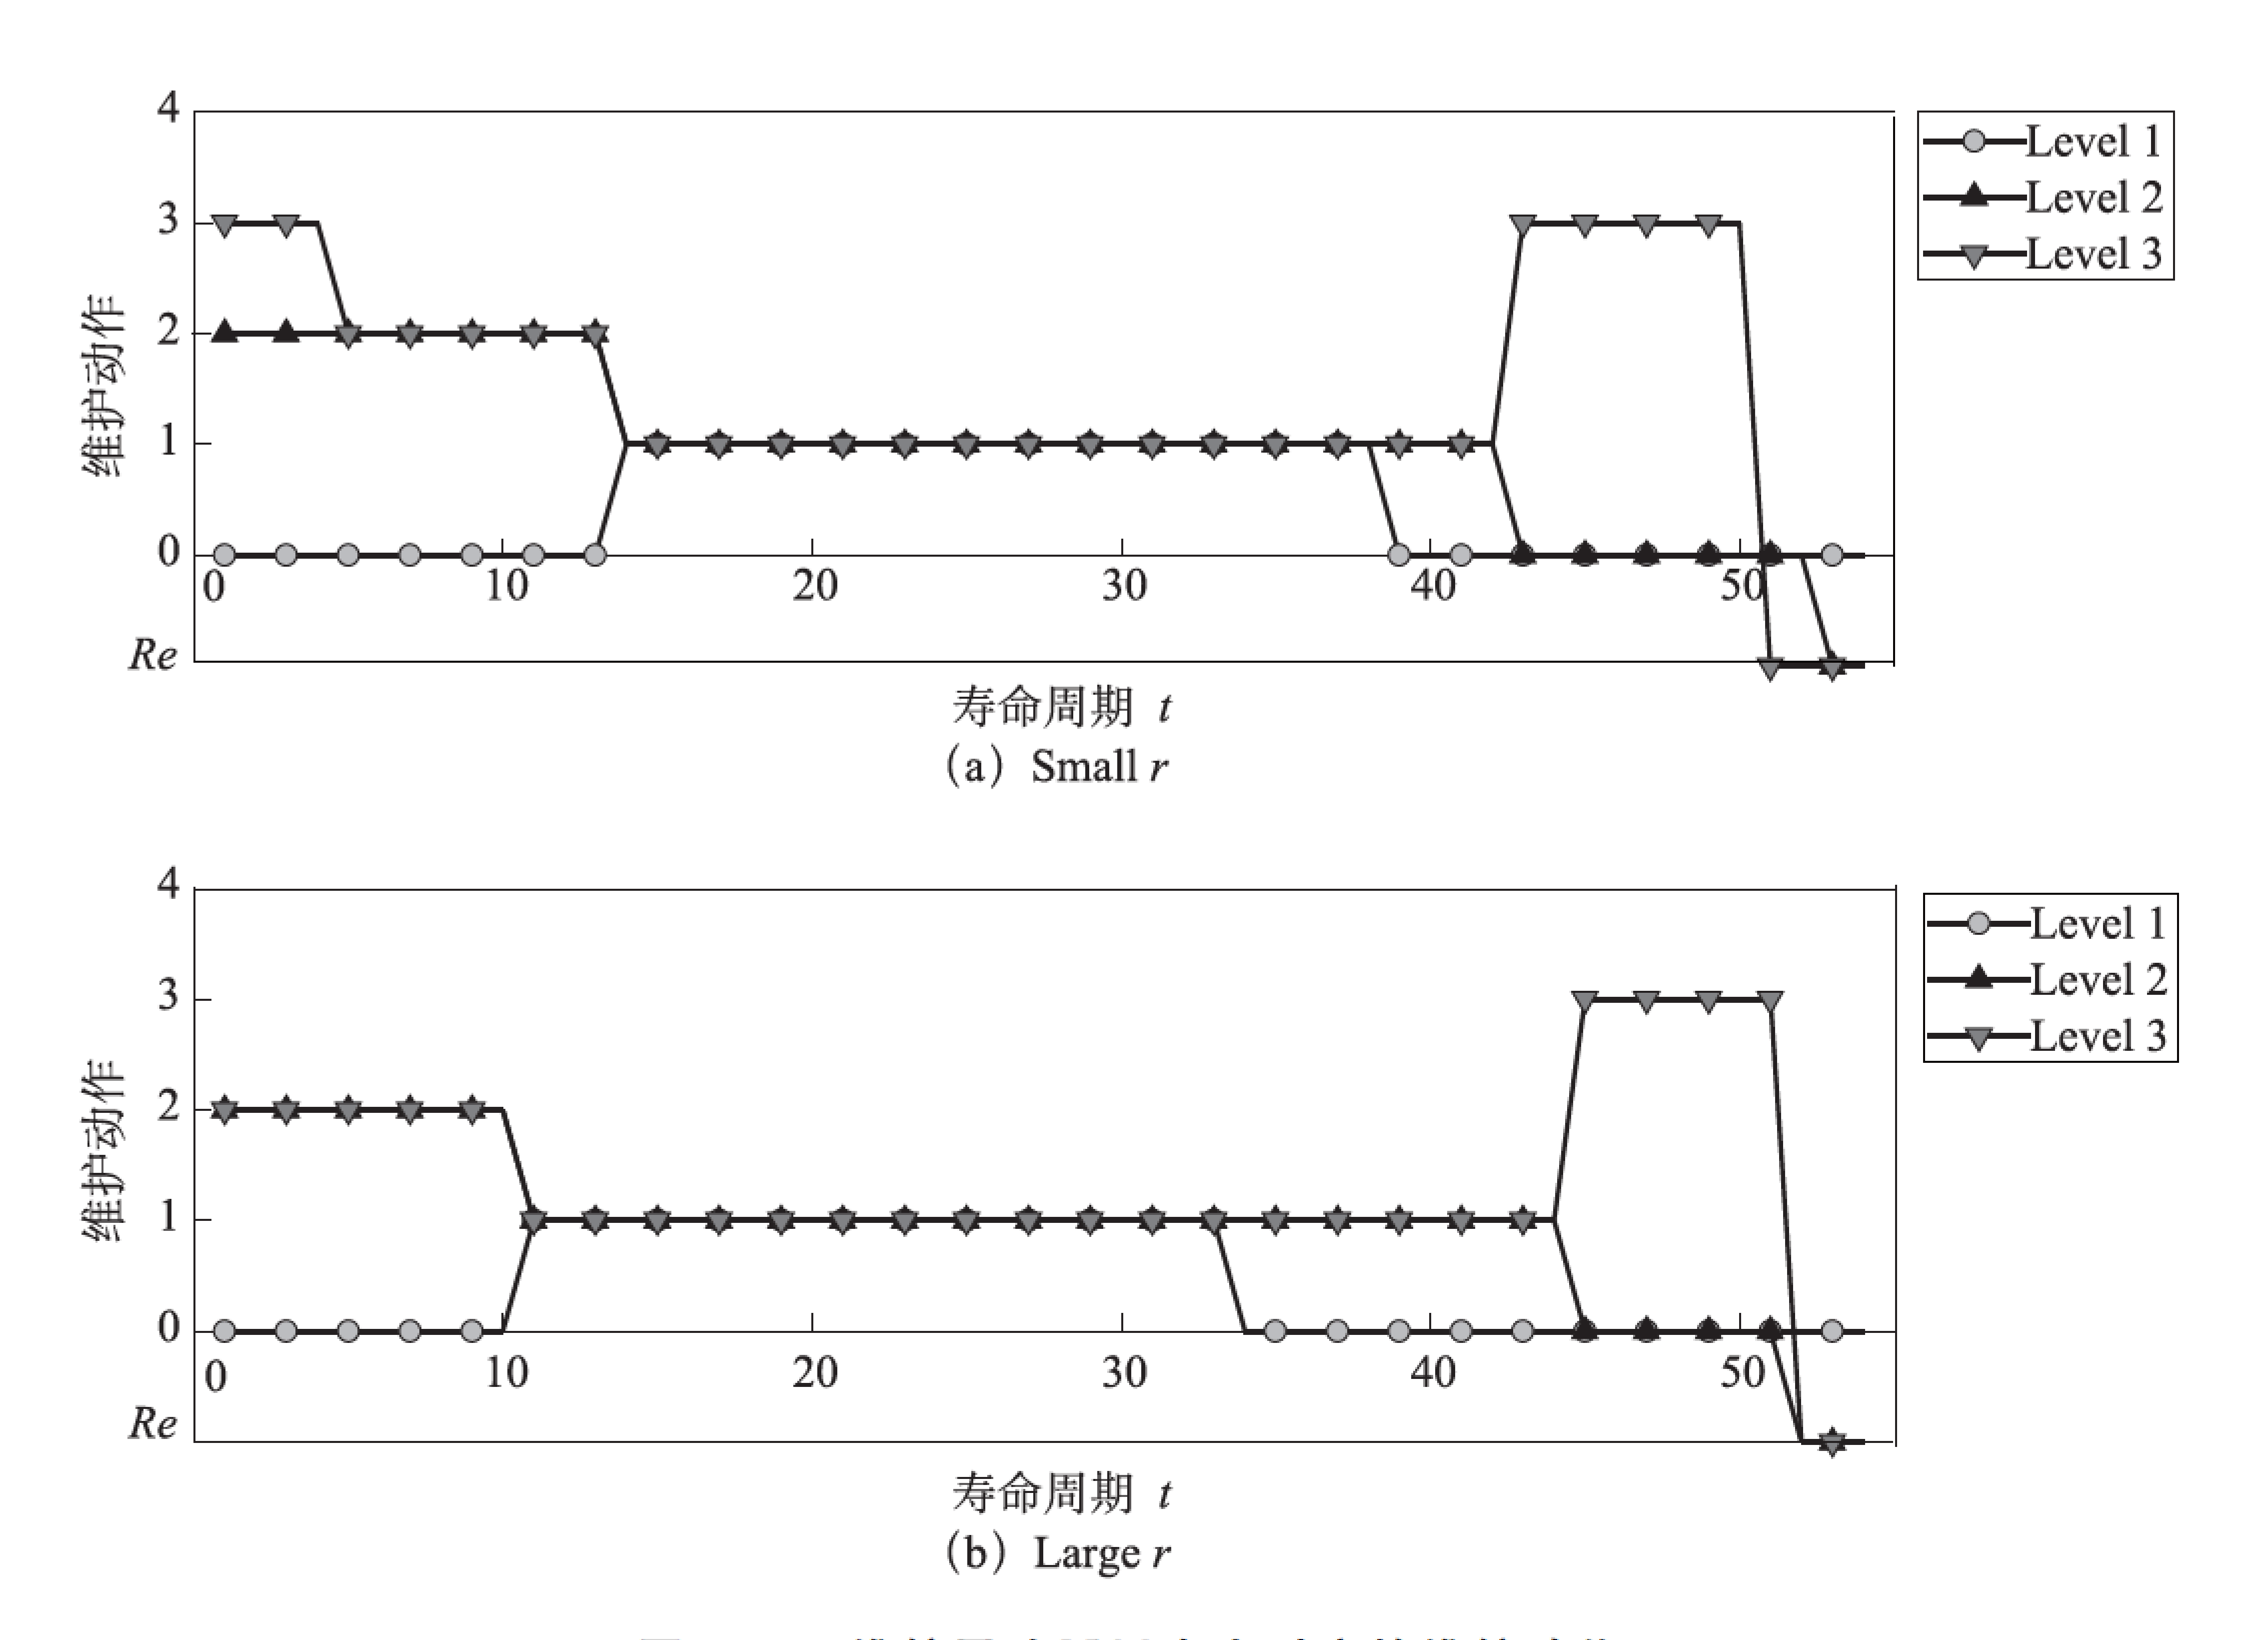


图 5-12 维护风险因子大小对应的维护动作

基于集成动态维护策略的动态分析,我们可以看出,针对不同的设备衰退模式、设备停机因子大小和设备的风险因子的大小,集成动态维护策略具有很好的动态性。并且,集成动态维护策略可以根据不同参数的变动,通过计算获得相应的最优维护动作和最优的维护策略。

5.6 本章小结

根据第3章和第4章中对设备的在线健康预测研究,本章内容探讨了考虑设备退化和老化、维护风险的维护问题,提出了集成动态维护模型。首先,对多传感器监测的数据信息进行有效处理,作为在线健康预测模型的输入。其次,考虑设备

的老化和退化，将设备的衰退信息集成到维护模型中。然后，利用在线健康预测模型识别设备的健康状态，获得健康状态间的转移概率，计算各个健康状态的驻留时间。对于每个健康状态，执行不同的维护动作来优化其到一个期望的目标。最后，提出双层集成动态维护模型，通过分析不同的维护动作，描述了不同的维护动作的影响。将不同的维护动作对维修人员和备件库存的需求与影响作为约束条件，集成到动态维护模型中。集成动态维护模型在达到最小化维修成本的同时，还可以获得最优的资源策略和最低的资源成本。提出的集成动态维护模型，充分考虑了设备的诊断信息和预测信息，考虑衰退信息和资源约束的集成动态维护模型是设备维护模型的延伸发展。通过案例分析，集成动态维护模型充分考虑了设备健康状态及衰退信息，在实用性和有效性方面也优于定期维护策略和纯动态维护策略。



第6章 基于集成维护模型的维护调度优化研究

6.1 引　言

对多部件设备来说，考虑设备内部的经济和结构相关性，在设备使用中，有时候因为某个部件的维护会导致设备的多个部件同时停止运转，因此，为了缩短设备在生产过程中的停机时间，减少对设备维护人员的调度次数，需要在每一次的维护活动中对性能衰退到一定程度的设备尽量进行维护。同时，在设备的维护过程中，由于受企业成本的限制，维护资源不可能无限地满足设备维护的需求，也就是说，受维护资源的限制，有时不可能同时进行多个维护动作，需要考虑多个维护动作的合理调度。因此，本章以设备的维护资源为约束条件，以每次维护活动的费用和总的维护费用率为优化目标，根据第5章的集成动态维护策略模型，建立了多部件设备的维护调度模型。

对于设备的维护调度，根据第5章的设备集成动态维护模型，本章通过故障阈值确定部件所采取的维护动作方式，当部件故障率达到某一个阈值时，就会相应地触发部件的维护活动。如果系统中的某一部件的故障率达到了小修的阈值，则需要对部件进行小修维护；如果某一部件的故障率达到了大修的阈值，则需要对部件

进行大修维护;如果某一部件的故障率达到了更换阈值,则需要对部件进行更换维护。因此,设备可以同时处理若干个维护动作,例如,部件 i 的故障率在 t 时刻达到了小修阈值,从而触发一次维护活动,而此时部件 j 故障率超过了更换阈值,部件 k 故障率超过了大修阈值,所以在本次维护活动中,也要对部件 j 和部件 k 进行相应的维护。

设备的维护调度不仅考虑了设备的衰退,还考虑了设备部件间的经济相关性、结构相关性和随机相关性。由于在某一时刻,可以同时采取多种维护动作,从而降低了对设备维护资源的频繁调度,减少了系统的启动和关闭费用,缩短了系统的停机时间,降低了设备的维护费用和停机费用,提高了设备利用率。因为维护资源约束的限制,需要同时确定设备的维护方式和调度策略,保证设备维护的实施和最小化维护费用,以每次维护活动的维护成本和设备生命周期内总费用率为优化目标,建立设备的维护调度模型。

6.2 设备维护调度优化模型

6.2.1 设备维护调度决策

设备的性能衰退是设备采取维护策略的基础,设备性能衰退的判断正确性影响采取的维护动作的方式,进而影响设备的维护效果。在本章中,用设备的故障率(failure rate,FR)来表示设备的性能状态,FR 越大,代表设备的衰退状态越严重,设备部件发生故障的概率增大。FR 可通过对设备进行在线监测和寿命预测获得(详见第 2 章和第 3 章),对于设备的故障率分析,针对不同类型的设备,由大量的故障历史数据的统计分析可知,一般设备的故障率都呈现“浴盆曲线”的分布形状。针对不同的“浴盆曲线”分布区域的特点,已经有多种分布来表示设备的故障率分布,如指数分布、威布尔分布、泊松分布、正态分布等,在这些分布中,以威布尔分布最为典型,因此,本章中的故障率分布采用威布尔分布来表示

$$FR(t)=\frac{\beta}{\eta}\left(\frac{t}{\eta}\right)^{\beta-1} \tag{6-1}$$

其中,β 为形状参数,η 为尺度参数,$\beta>0$,$\eta>0$。

威布尔分布的工程适用范围比较广，通过调整形状参数、尺度参数等，它可以拟合多种故障数据。根据可靠性理论，对威布尔的故障分布进行分析，在 η 保持不变的情况下，如果 $\beta<1$，说明设备的故障率为下降趋势；如果 $\beta=1$，说明设备的故障率保持不变，为一个常数；如果 $\beta>1$，则设备的故障率将呈现递增的趋势。这说明威布尔分布针对不同的参数取值，都可以精确实现对设备故障率曲线的描述。因为威布尔分布具有以上这些优点，所以在本章中，采用威布尔分布来描述设备的故障率分布。设备运转过程中的故障率随着运行时间的增加逐渐升高，因此，为了延长设备的使用时间和寿命，要在出现故障之前对设备采取维护措施。

为了减缓设备性能的退化，采取各种不同的维护动作，如更换零件、小修等。并且，对于不同的设备退化状态，采取不同的维护动作，可以将设备状态优化至不同的目标值。根据设备所处的健康状态和退化程度，对设备采取不同的维护动作，进而产生不同的维护效果。有多种不同的维护动作可以选择，具体的维护动作的集合表示如下。

小修（用 M 表示）：对设备采取有限的维护工作，也就是对设备进行保养维护，仅仅对设备进行润滑、调节、除尘等一系列保养工作，目的就是让设备尽可能地保持在当前的健康状态 h_i，以及设备的衰退程度与维修之前相比有较小的改善。在本章中，用 F_M 表示对部件进行小修的故障率阈值。

大修（用 I 表示）：对设备采取较为充分的维修工作，对设备进行修复，修复部分部件的损耗。维修的目的就是让设备从当前健康状态 h_i 恢复到一个更好的健康状态 h_j，使设备的衰退状态得到显著改善。在本章中，用 F_I 表示对部件进行大修的故障率阈值。

更换（用 R 表示）：对设备进行更换，直接用新的零部件更换发生故障或者损耗的设备零部件，在这种情况下，设备将恢复到初始健康状态 h_1，使衰退的设备恢复到全新状态，或者使用新设备代替原设备工作。在本章中，用 F_R 表示对部件进行更换的故障率阈值。

设备在经过维护后，会有不同程度的恢复，我们用故障率的变化趋势来分析设备的恢复情况，具体的维护效果如图 6-1 所示。图 6-1 中的 (t_M, t_I) 时间段的故障率曲线表示小修之后设备的维护效果情况，设备小修之后当前设备的故障率不发生变化，设备的衰退速度变缓。(t_I, t_R) 时间段的故障率曲线表示设备大修后的维护效果，在设备大修之后，设备的运转性能得到明显的恢复，设备的衰退速度也相应的得到降低。t_R 之后的故障率曲线表示设备置换后的维护效果，在置换以后，设

备的性能得到完全恢复，设备的衰退速度也相应地降低。

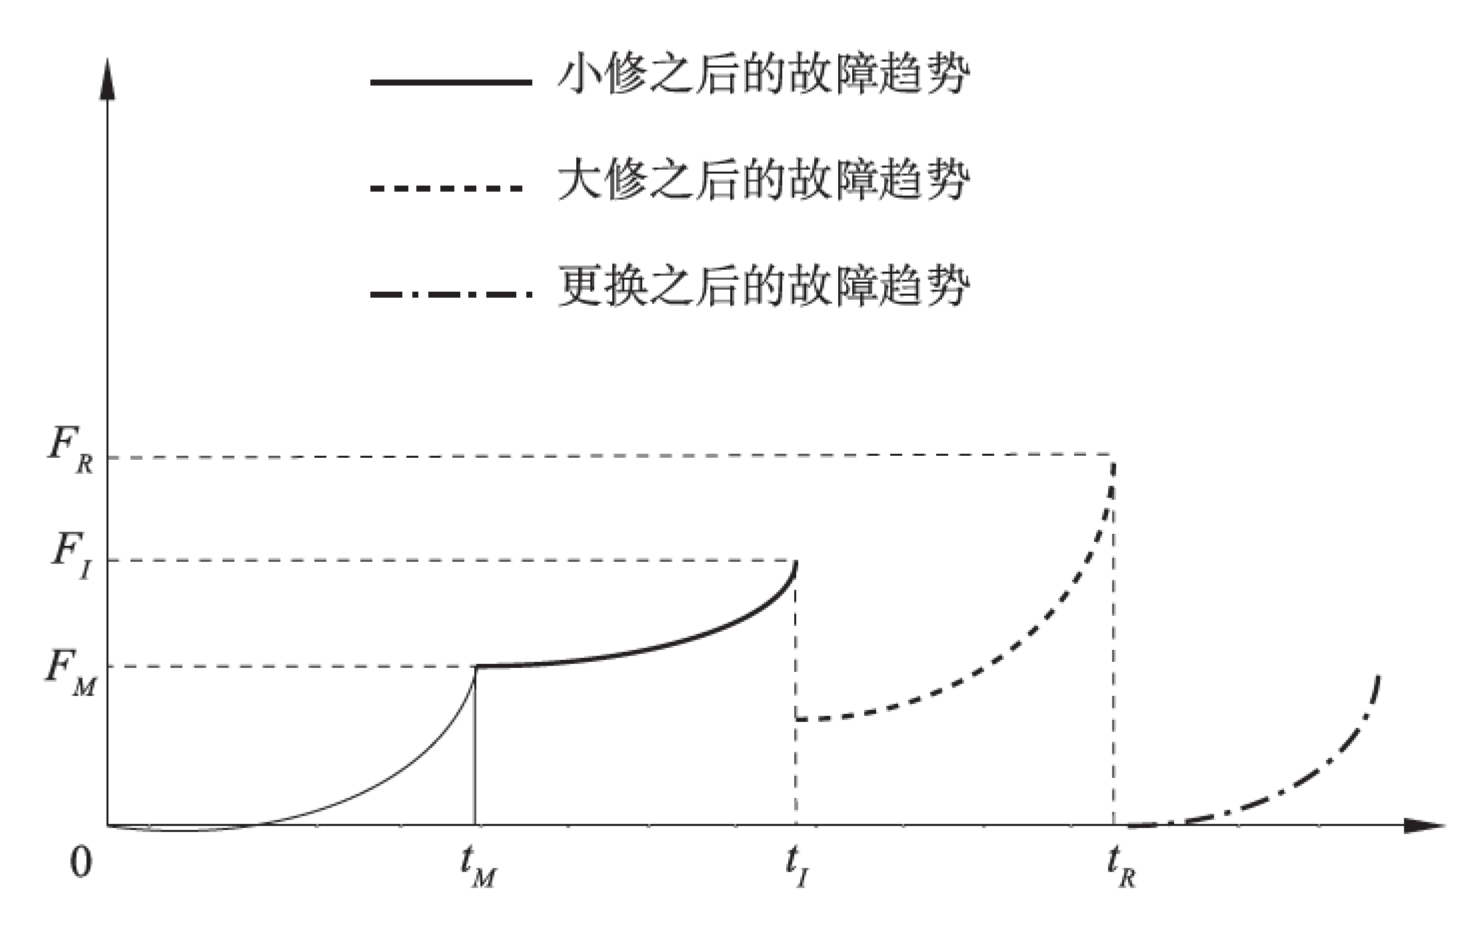


图 6-1　不同维护动作的维修效果

用不同的威布尔参数（β 和 η）来表示每一部件采取的不同的维护动作后的效果，如表 6-1 所示。表中的 i 是设备部件数量的标记（例如 $i=1$，表示设备的第 1 个部件）。

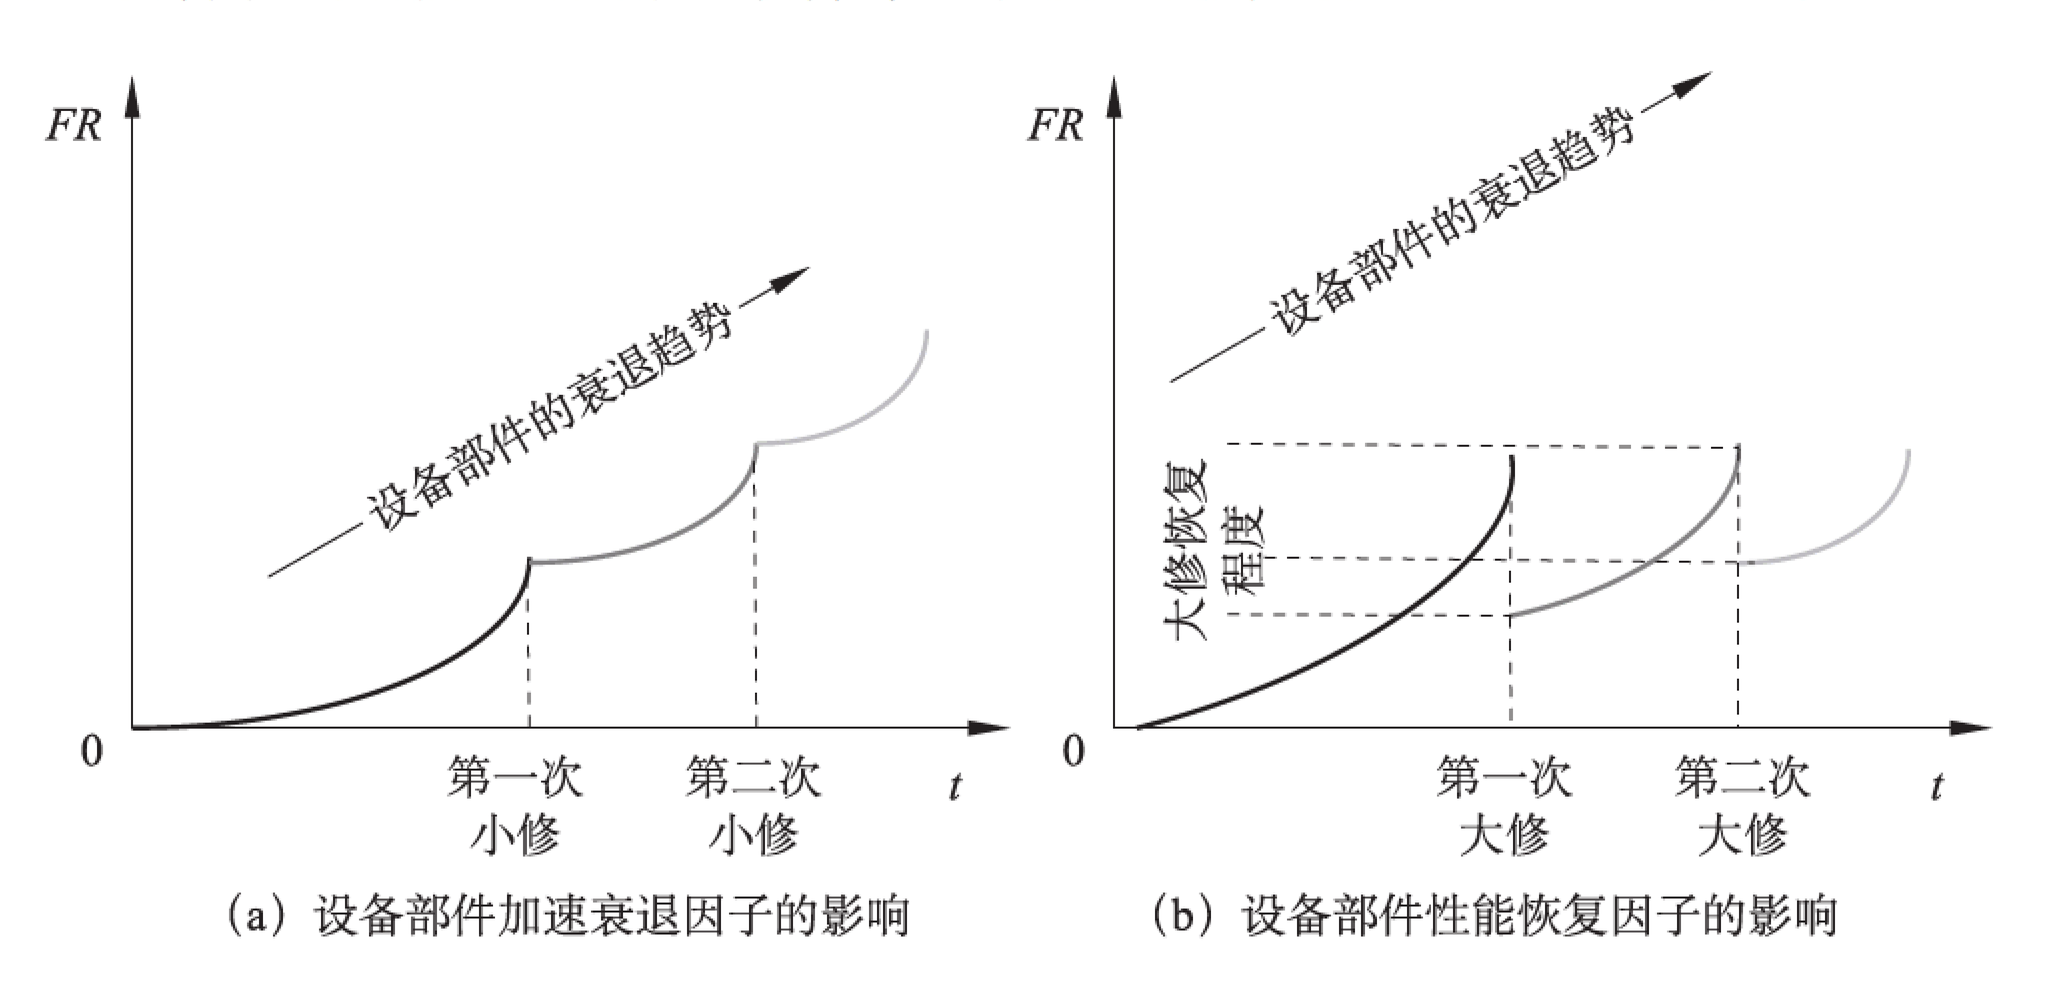
表 6-1　对于不同部件的不同维护动作的威布尔参数

维护动作	形状参数 β	尺度参数 η
小修	$\beta_{i,M}$	$\eta_{i,M}$
大修	$\beta_{i,I}$	$\eta_{i,I}$
更换	$\beta_{i,R}$	$\eta_{i,R}$

根据三种维护阈值，我们可以确定部件采取的维护动作的方式，设备在运转过程中，当某一设备部件的故障率达到维护阈值时，例如达到大修的维护阈值，为了降低设备的维护时间和提高系统整体利用率，对于其他设备部件，如果也达到了维护阈值，则对这些设备部件也要采取维护方式，也就是连带维护。设备的故障率随着设备性能的逐渐衰退可以根据表 5-1 中的威布尔参数进行确定，从而对部件采取相应的维护措施。

在企业的实际生产过程中，随着设备使用时间和部件维护次数的增加，实际维护动作（小修和大修）的效果会随着维护次数的增多而逐渐降低，从而设备的衰退速度增加。基于这种情况，我们将在设备的维护效果模型中引入设备加速衰退因子和设备的性能恢复因子这两个调整因子。其中，设备的加速衰退因子可以加快设备性能的衰退速率，如果在设备的小修中，引入设备的加速衰退因子，则随着设

备小修次数的增多，设备的衰退将明显加快。根据设备的性能恢复因子可以计算设备采取维护后的初始故障率，引入设备的性能恢复因子后，随着设备大修次数的增多，设备衰退速度不断增加，故障率也恢复得越来越少，如图 6-2 所示。



(a) 设备部件加速衰退因子的影响　(b) 设备部件性能恢复因子的影响

图 6-2　调整因子对设备维护动作效果的影响

在引入设备的加速衰退因子的情况下，设备的第 i 个部件的在时刻 t 的小修故障率模型为

$$FR_M(t) = FR_M(t_0) + FR_M(t, \beta_{i,M}, \eta_{i,M} \times \theta) \tag{6-2}$$

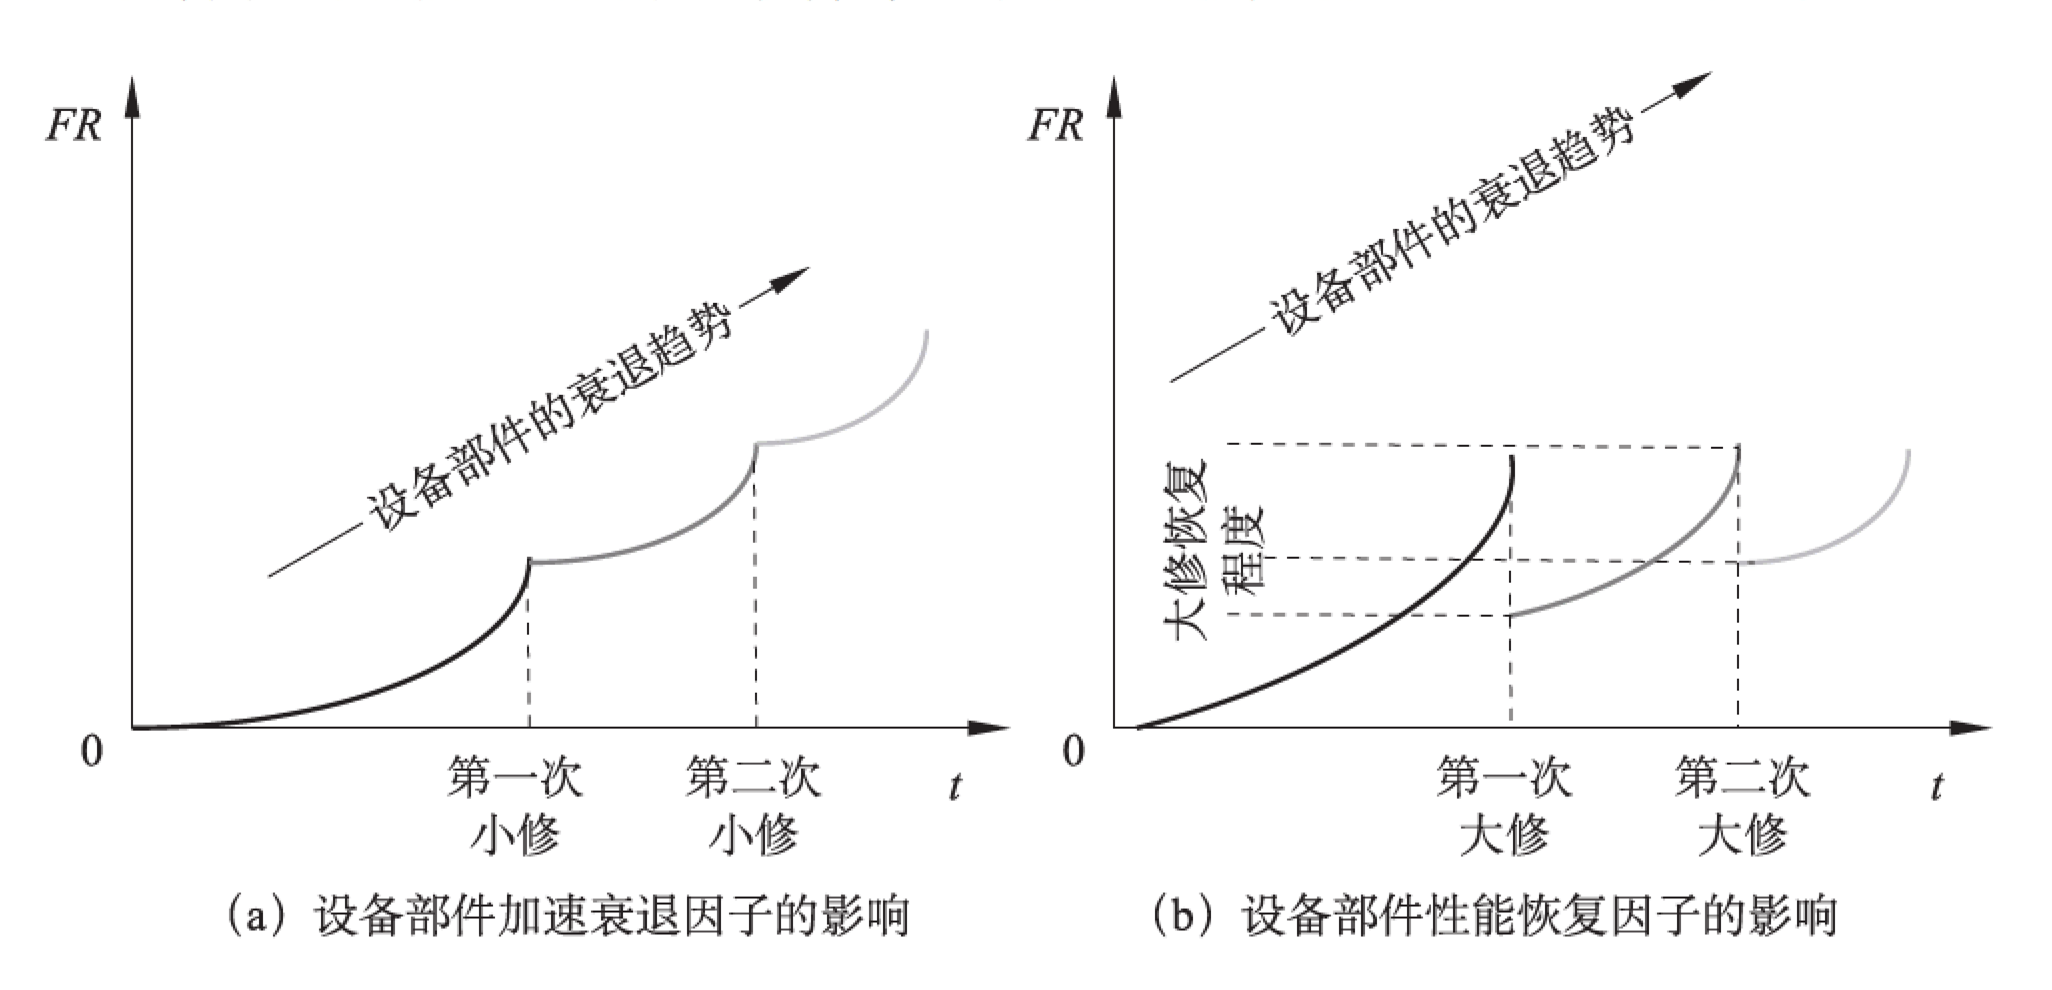
其中，$FR_M(t_0)$表示设备部件小修之前的故障率，θ 表示设备部件的加速衰退因子($0<\theta<1$)。为了描述设备部件的衰退效果，设备部件的加速衰退因子可以表示为$\theta=a^{MN}$，a 是根据设备部件的历史数据来获得($0<a<1$)，MN 是设备部件截至当前时刻，所经历过的小修次数。从表达式可以看出，小修次数越多，θ 越小，从而设备部件的故障率曲线就会变陡，在设备部件第一次小修时，$MN=0$。

在引入设备的加速衰退因子和设备的性能恢复因子的情况下，设备的第 i 个部件的在时刻 t 的大修故障率模型为

$$FR_I(t) = (1-\varphi)FR_I(t_0) + FR_I(t, \beta_{i,I}, \eta_{i,I} \times \theta) \tag{6-3}$$

其中，$FR_I(t_0)$表示设备部件大修之前的故障率，φ 表示设备部件的性能恢复因子($0<\varphi<1$)。为了描述设备部件的性能恢复，设备部件的性能恢复因子可以表示为$\varphi=b^{IN}$，b 是根据设备部件的历史数据来获得($0<b<1$)，IN 是设备部件截至当前时刻，所经历过的大修次数。从表达式可以看出，大修次数越多，φ 越小，从而设备部件维护后的初始故障率$(1-\varphi)FR_I(t_0)$越大，设备部件故障率恢复得越少，在设备部件第一次大修时，$IN=0$。

备小修次数的增多,设备的衰退将明显加快。根据设备的性能恢复因子可以计算设备采取维护后的初始故障率,引入设备的性能恢复因子后,随着设备大修次数的增多,设备衰退速度不断增加,故障率也恢复得越来越少,如图 6-2 所示。



(a) 设备部件加速衰退因子的影响　(b) 设备部件性能恢复因子的影响

图 6-2　调整因子对设备维护动作效果的影响

在引入设备的加速衰退因子的情况下,设备的第 i 个部件的在时刻 t 的小修故障率模型为

$$FR_M(t) = FR_M(t_0) + FR_M(t, \beta_{i,M}, \eta_{i,M} \times \theta) \tag{6-2}$$

其中,$FR_M(t_0)$表示设备部件小修之前的故障率,θ 表示设备部件的加速衰退因子($0<\theta<1$)。为了描述设备部件的衰退效果,设备部件的加速衰退因子可以表示为$\theta=a^{MN}$,a 是根据设备部件的历史数据来获得($0<a<1$),MN 是设备部件截至当前时刻,所经历过的小修次数。从表达式可以看出,小修次数越多,θ 越小,从而设备部件的故障率曲线就会变陡,在设备部件第一次小修时,$MN=0$。

在引入设备的加速衰退因子和设备的性能恢复因子的情况下,设备的第 i 个部件的在时刻 t 的大修故障率模型为

$$FR_I(t) = (1-\varphi)FR_I(t_0) + FR_I(t, \beta_{i,I}, \eta_{i,I} \times \theta) \tag{6-3}$$

其中,$FR_I(t_0)$表示设备部件大修之前的故障率,φ 表示设备部件的性能恢复因子($0<\varphi<1$)。为了描述设备部件的性能恢复,设备部件的性能恢复因子可以表示为$\varphi=b^{IN}$,b 是根据设备部件的历史数据来获得($0<b<1$),IN 是设备部件截至当前时刻,所经历过的大修次数。从表达式可以看出,大修次数越多,φ 越小,从而设备部件维护后的初始故障率$(1-\varphi)FR_I(t_0)$越大,设备部件故障率恢复得越少,在设备部件第一次大修时,$IN=0$。

在本章的设备维护调度分析中，为了更好地对设备的维护调度策略进行研究，对以上两种情况都进行分析，一种是基于方程(6-1)的普通故障率模型；一种是基于方程(6-2)和方程(6-3)，引入设备部件衰退因子和性能恢复因子的故障率模型，并且与定期维护调度策略相比较。

对于设备的维护调度，在每一次的维护活动时，都会发生很多次的小修、大修和更换的维护动作。因此，设备的总成本目标包括设备的维护成本 C_m、设备的故障成本 C_f 和设备的资源成本 C_r。同时，在考虑设备利用率的基础上，设备的维护动作所引起的停机产生的停机成本 C_d 也被集成到设备的维护成本模型中，因此，综合考虑设备成本和设备利用率的一次维护活动的成本模型表示为

$$C_T = C_f + C_m + C_r + C_d \tag{6-4}$$

在方程(6-4)中，一次维护活动的设备故障成本模型可以表示为

$$C_f = FF \times \bigcup_{i}^{n} FR(i,t) + \sum_{i=1}^{n} F_i \times FR(i,t) \tag{6-5}$$

其中，FF 表示设备的故障独立成本；$FR(i,t)$ 表示部件 i 在维护时刻 t 的故障率。F_i 是部件的故障依赖成本，与维护动作无关。n 表示部件的数量。

一次维护活动的设备维护成本模型可以表示为

$$\begin{aligned} C_m &= C_{M,m} + C_{I,m} + C_{R,m} \\ &= FM \times \left(\sum_{i=1}^{n} X_{M,i,t} + \sum_{i=1}^{n} X_{I,i,t} + \sum_{i=1}^{n} X_{R,i,t} \right) + \sum_{i=1}^{n} M_{M,i} \times \\ & \quad X_{M,i,t} + \sum_{i=1}^{n} M_{I,i} \times X_{I,i,t} + \sum_{i=1}^{n} M_{R,i} \times X_{R,i,t} \end{aligned} \tag{6-6}$$

其中，$C_{M,m}$，$C_{I,m}$，$C_{R,m}$ 分别表示部件 i 的小修维护成本、大修维护成本和置换维护成本。FM 表示部件的维护独立成本，与维护动作无关。$X_{M,i,t}$ 表示在时刻 t 对部件 i 是否进行小修，如果对部件 i 在时刻 t 进行小修，则 $X_{M,i,t}=1$；否则，$X_{M,i,t}=0$。$X_{I,i,t}$ 表示在时刻 t 对部件 i 是否进行大修，如果对部件 i 在时刻 t 进行大修，则 $X_{I,i,t}=1$；否则，$X_{I,i,t}=0$。$X_{R,i,t}$ 表示在时刻 t 对部件 i 是否进行置换，如果对部件 i 在时刻 t 进行置换，则 $X_{R,i,t}=1$；否则，$X_{R,i,t}=0$。$M_{M,i}$，$M_{I,i}$，$M_{R,i}$ 分别表示部件 i 的小修维护依赖成本、大修维护依赖成本和置换依赖维护成本。

一次维护活动的资源成本模型可以表示为

$$
\begin{aligned}
C_r &= C_{r1} + C_{r2} + C_{r3} \\
&= c_s \times \text{Max}\left(\left(\sum_{i=1}^{n}(Q_{M,s,i} \times X_{M,i,t} + Q_{I,s,i} \times X_{I,i,t} + Q_{R,s,i} \times X_{R,i,t}) - \right.\right. \\
&\quad \left.\left. H_{s,t}\right), 0\right) + c_r \times \text{Max}\left(\left(\sum_{i=1}^{n}(Q_{M,r,i} \times X_{M,i,t} + Q_{I,r,i} \times X_{I,i,t} + \right.\right. \\
&\quad \left.\left. Q_{R,r,i} \times X_{R,i,t}) - H_{r,t}\right), 0\right) + c_g \times \text{Max}\left(\left(\sum_{i=1}^{n}(Q_{M,g,i} \times \right.\right. \\
&\quad \left.\left. X_{M,i,t} + Q_{I,g,i} \times X_{I,i,t} + Q_{R,g,i} \times X_{R,g,t}) - H_{s,t}\right), 0\right)
\end{aligned}
\tag{6-7}
$$

其中，C_{r1}，C_{r2}，C_{r3} 分别表示备件缺货成本、维修人员缺少成本和维修工具成本。c_s 表示对设备进行维护缺少所需要备件的惩罚系数。$Q_{M,s,i}$、$Q_{I,s,i}$、$Q_{R,s,i}$ 分别表示对部件 i 进行小修、大修和置换所需要的备件 s 的数量。$H_{s,t}$ 表示在时刻 t 具有的备件 s 的数量。c_r 表示对设备进行维护缺少维修人员 r 的惩罚系数。$Q_{M,r,i}$、$Q_{I,r,i}$、$Q_{R,r,i}$ 分别表示对部件 i 进行小修、大修和置换所需要的维修人员 r 的数量。$H_{r,t}$ 表示在时刻 t 具有的维修人员 r 的数量。c_g 表示对设备进行维护缺少维护工具 g 的惩罚系数。$Q_{M,g,i}$、$Q_{I,g,i}$、$Q_{R,g,i}$ 分别表示对部件 i 进行小修、大修和置换所需要的维修工具 g 的数量。$H_{g,t}$ 表示在时刻 t 具有的维修工具 g 的数量。

对维修人员和维修工具来说，如果在某时刻缺少这部分资源，则需要等待，而在某维修时刻缺少备件的话，则需要进行订货，因此，维修人员和维修工具的惩罚系数要大于备件的惩罚系数。在方程(6-8)，$H_{q,t}$ 等于 $t-1$ 时刻的可用资源数量与 t 时刻到达或者释放的资源数量减去 $t-1$ 时刻所需要的资源数量。因此，$H_{q,t}$ 的表达式可以表示为

$$
\begin{aligned}
H_{q,t} = H_{q,t-1} + A_{r,t} - \sum_{i=1}^{n}(Q_{M,q,i} \times X_{M,i,t-1} + Q_{I,q,i} \times \\
X_{I,i,t-1} + Q_{R,q,i} \times X_{R,i,t-1})
\end{aligned}
\tag{6-8}
$$

其中，$H_{q,t-1}$ 表示在时刻 $t-1$ 具有的资源 q 的数量。$A_{q,t}$ 表示在时刻 t 到达或者释放的可用资源 q 的数量。q 分别等于 s，r，g。

一次维护活动的设备停机成本模型可以表示为

$$C_d = CA \times \sum_{i=1}^{n} \left[\begin{aligned} & X_{M,i,t}\left(T_{M,i}(1+N_i) - \sum_{j=1}^{N_i} T_{ij}^0\right) + \\ & X_{I,i,t}\left(T_{I,i}(1+N_i) - \sum_{j=1}^{N_i} T_{ij}^0\right) + \\ & X_{R,i,t}\left(T_{R,i}(1+N_i) - \sum_{j=1}^{N_i} T_{ij}^0\right) \end{aligned} \right] \tag{6-9}$$

其中,CA 表示设备单位时间的停机成本。$T_{M,i}$、$T_{I,i}$、$T_{R,i}$分别表示部件 i 的小修维护时间、大修维护时间和置换维护时间。N_i表示设备的预计停机数,即部件 i 停机维修时,所导致的其他停机部件的数量,当确定部件 i 的预计停机数时,假设其他部件状态是良好的,且没有故障。$T_{ij}{}^0$表示第 i 个部件和第 j 个部件同时维护所节约的时间。

基于方程(6-5)～方程(6-9),可以获得设备一次维护活动的总成本模型 C_T。

$$\begin{aligned} C_T = {} & FF \times \bigcup_{i}^{n} FR(i,t) + \sum_{i=1}^{n} F_i \times FR(i,t) + \\ & FM \times \left(\sum_{i=1}^{n} X_{M,i,t} + \sum_{i=1}^{n} X_{I,i,t} + \sum_{i=1}^{n} X_{R,i,t}\right) + \sum_{i=1}^{n} M_{M,i} \times X_{M,i,t} + \\ & \sum_{i=1}^{n} M_{I,i} \times X_{I,i,t} + \sum_{i=1}^{n} M_{R,i} \times X_{R,i,t} + \\ & c_s \times \mathrm{Max}\left(\left(\sum_{i=1}^{n} (Q_{M,s,i} \times X_{M,i,t} + Q_{I,s,i} \times X_{I,i,t} + Q_{R,s,i} \times \right.\right. \\ & \left.\left. X_{R,i,t}) - H_{s,t}\right), 0\right) + c_r \times \mathrm{Max}\left(\left(\sum_{i=1}^{n} (Q_{M,r,i} \times X_{M,i,t} + \right.\right. \\ & \left.\left. Q_{I,r,i} \times X_{I,i,t} + Q_{R,r,i} \times X_{R,i,t}) - H_{r,t}\right), 0\right) + c_g \times \\ & \mathrm{Max}\left(\left(\sum_{i=1}^{n} (Q_{M,g,i} \times X_{M,i,t} + Q_{I,g,i} \times X_{I,i,t} + \right.\right. \\ & \left.\left. Q_{R,g,i} \times X_{R,i,t}) - H_{g,t}\right), 0\right) + \\ & CA \times \sum_{i=1}^{n} \left[\begin{aligned} & X_{M,i,t}\left(T_{M,i}(1+N_i) - \sum_{j=1}^{N_i} T_{ij}^0\right) + \\ & X_{I,i,t}\left(T_{I,i}(1+N_i) - \sum_{j=1}^{N_i} T_{ij}^0\right) + \\ & X_{R,i,t}\left(T_{R,i}(1+N_i) - \sum_{j=1}^{N_i} T_{ij}^0\right) \end{aligned} \right] \end{aligned} \tag{6-10}$$

方程(6-10)表示了对设备进行一次维护活动的总费用模型,实际上,在设备运转的全生命周期里会产生不止一次的维护活动。设备从初始的健康状态开始运转,在运转过程中,如果某一部件的故障率达到或者超过部件的维护阈值,则会给该设备触发一次维护活动,设备维护后,设备的性能会得到恢复,并投入使用,在后续的使用过程中,设备的故障率不断提高,直到故障率又达到设备的维护阈值,则会给该设备触发二次维护,以此类推,直到设备的全寿命周期终止。因此,在设备的每一次的维护活动的费用基础上,也要考虑设备在整个生命周期内的多阶段的维护调度的总费用,设备总费用率的方程可以表示为

$$C_{\text{Total}} = \left(\sum_{j=1}^{m} C_{j,T} + m \times c_q\right)/D \tag{6-11}$$

其中,C_{Total}表示设备维护调度的总费用率。$C_{j,T}$表示设备进行第j次维护活动所产生的总费用。D表示设备的全寿命周期。m表示设备在全寿命周期内所执行的维护活动的总次数。c_q表示设备在执行一次维护活动时,所产生的设备启动费用。

基于方程(6-11),可以看出,为了让整个设备的全生命周期的维护调度总费用率最小,不但要考虑设备在执行每一次维护时所产的故障费用、维护费用、资源费用和停机损失,还要考虑设备在全生命周期内的维护活动的次数要尽量少。只有优化这两个目标,设备的总费用率才会降低,因此,设备的全生命周期的维护调度总费用率具有全局性的特点。

6.2.2 遗传算法

GA是模拟生物进化过程而进行的一种多参数、多群体同时优化的方法,并行性和解空间的全局搜索是其最大的特征,限制性条件的约束不影响其优化过程,GA的编码技术简单,且容易操作。简单的GA主要是由选择(selection)、交叉(crossover)和变异(mutation)三种基本形式构成。在求解模型过程中,首先把问题的解空间映射为编码空间,产生初始种群开始其搜索,模型的每一解表示为一个染色体,染色体是由基因组成的,在后续的迭代过程中,染色体不断发生进化。其次,用模型的适应度衡量染色体的优劣,并且,通过选择、交叉和变异的运算,生成下一代染色体,也就是后代。最后,在新的群体中,凭借模型适应度的优劣选择部分后代,淘汰部分后代,这样,保持了种群的优越性和数量的限制。在迭代过程中,以较大的概率选中适应度高的染色体和淘汰适应度低的染色体,反复重复这个操

作，目标向着模型最优解的方向不断地进行代数进化，从而一个最适应优化环境的群体且满足求解模型最优解收敛条件被获得，通过对模型的不断迭代优化，最终所求解模型的近似解或者模型的最优解被获得。GA 在求解模型中的优化过程如图 6-3。

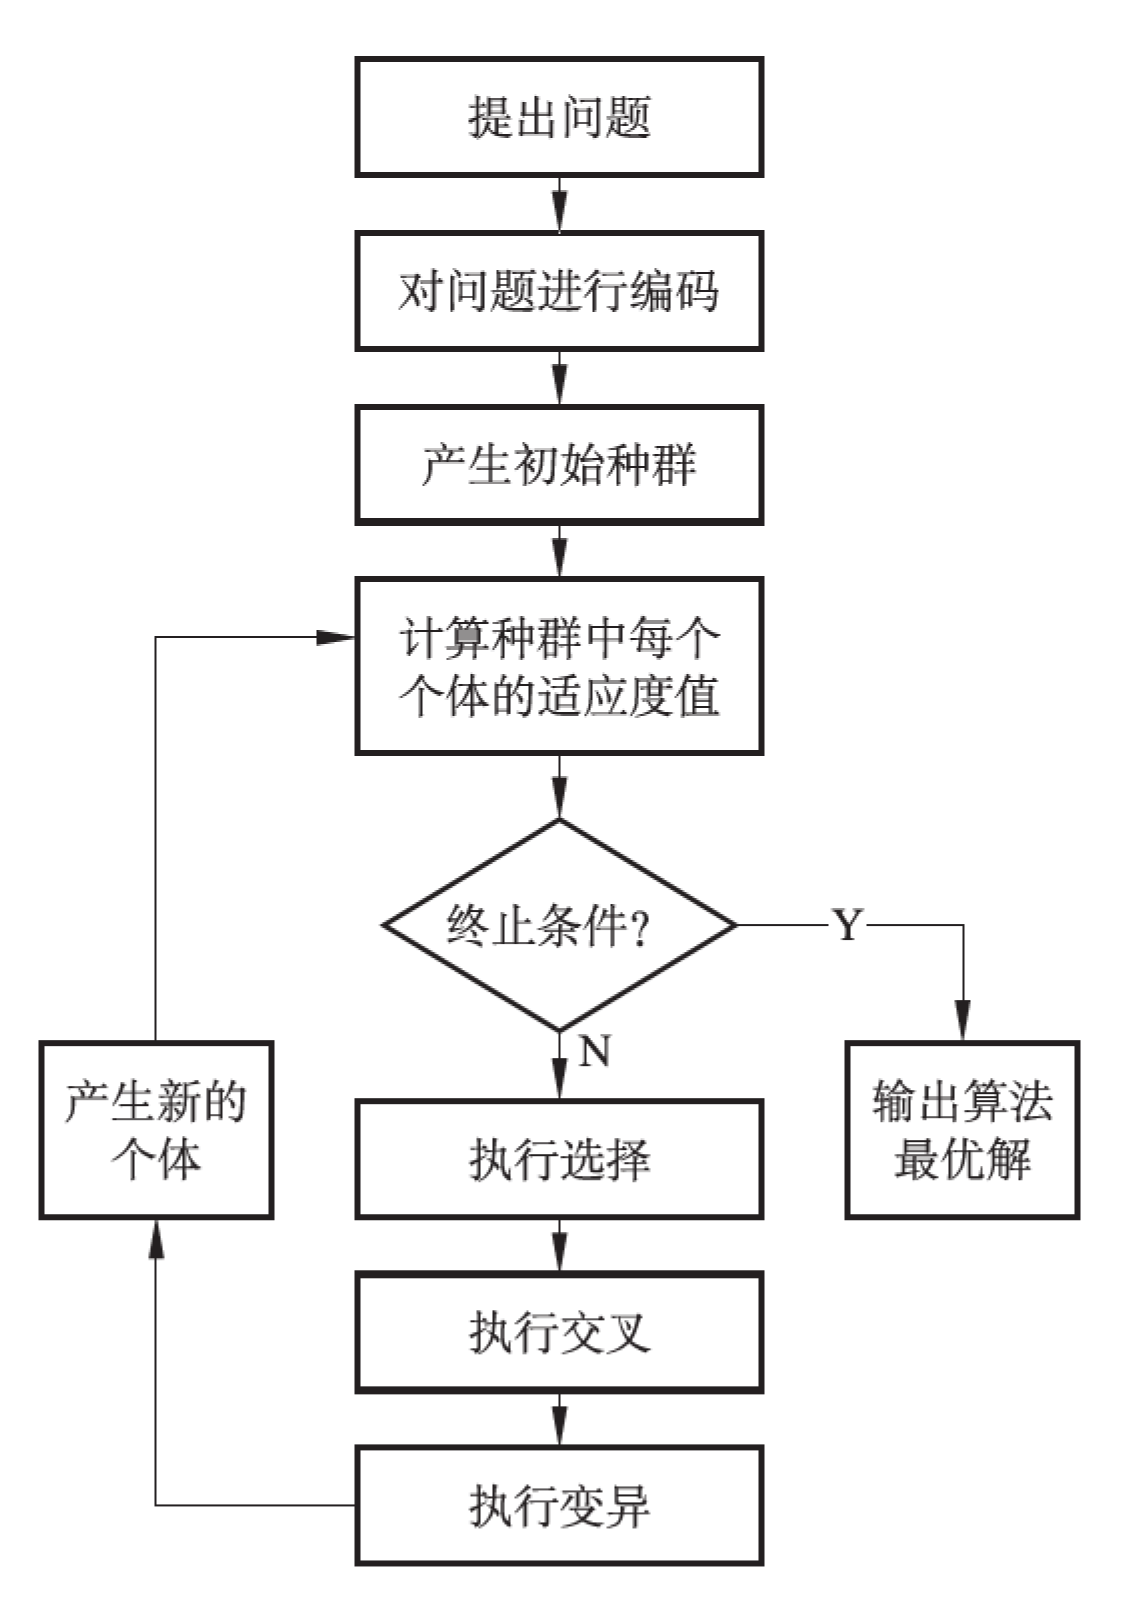


图 6-3　遗传算法的基本流程

对于图 6-3 中遗传算法的基本要素如下。

(1) GA 的编码要素。是 GA 的一种解的转换方式，也就是对优化模型的可行解执行了一个从解空间到搜索空间的转换。也就是说，编码是 GA 的首要要素，针对不同的优化模型，编码是不同的。并且，编码要素影响 GA 的其他要素。

(2) 适应度函数。是算法进行过程中的衡量标准，主要表示了 GA 群体中的每个个体在优化模型的运算过程中发现模型最优解的好坏标准，这一标准也是 GA 在迭代过程中进行自然选择的重要依据。不同的问题，适应度函数的定义方式也有所不同。

(3) 选择。使群体中的优良个体可以以更大的概率生存，防止有效基因的消

失，提高算法的全局收敛性和迭代的计算效率。用适应度值判断个体的优劣，适应度值越大的个体，就具有越多的选择机会，充分体现了“优胜劣汰，适者生存”的原则，越优良的个体越有机会得到保留，从而产生下一代个体。

(4) 交叉。在算法迭代过程中，有两个个体从群体中以较大的概率被选择，对选择的这两个个体执行交叉操作，产生了承继了算法前代基本特征的子代。GA的交叉操作表示对选择的两个染色体，通过某种交换方式，执行染色体部分基因的相互交换操作，进行形成了群体中的新的染色体。交叉是GA产生新个体的主要方法，也是GA有别于其他的智能进化算法。

(5) 变异。主要表示了由于发生基因替换操作产生了GA群体中的新的染色体。在替换操作过程中，变异要素具有随机性，从而增加了算法的变异操作，不同于选择和交叉的丢失信息，它可以有效地保留信息。GA的新个体主要是由交叉操作所产生，也影响GA的全局最优解的进化能力，在GA产生新个体的过程中，变异操作是一种辅助方法，影响GA的局部最优解的进化能力。通过这两种操作的相互配合，使GA可以很好地完成全局和局部最优解的搜索。

6.3 案例分析

在本章的案例分析中，我们仍以液压泵(设备)为研究对象。液压泵的运转是8个部件相互协作完成的，因此，对液压泵进行维护调度，就是对液压泵的8个部件进行维护调度。另外，该液压泵在使用运行过程中，随着使用时间的增加，液压泵的性能会逐渐衰退，液压泵的健康状态会逐渐变差，因而，需要对液压泵进行相应的维护使其维持正常的工作，避免液压泵失效带来的高成本和高风险。并且，随着液压泵使用运行成本和维护成本的不断增加，也可以考虑实施置换维护。因此，维护调度以优化每阶段的维护调度费用和总的费用率为目标，制定维护策略，液压泵的8个部件的相关关系如图6-4所示。本算例应用遗传算法进行求解，数据分析所用运行平台为Matlab、VC，运行环境为Windows XP。

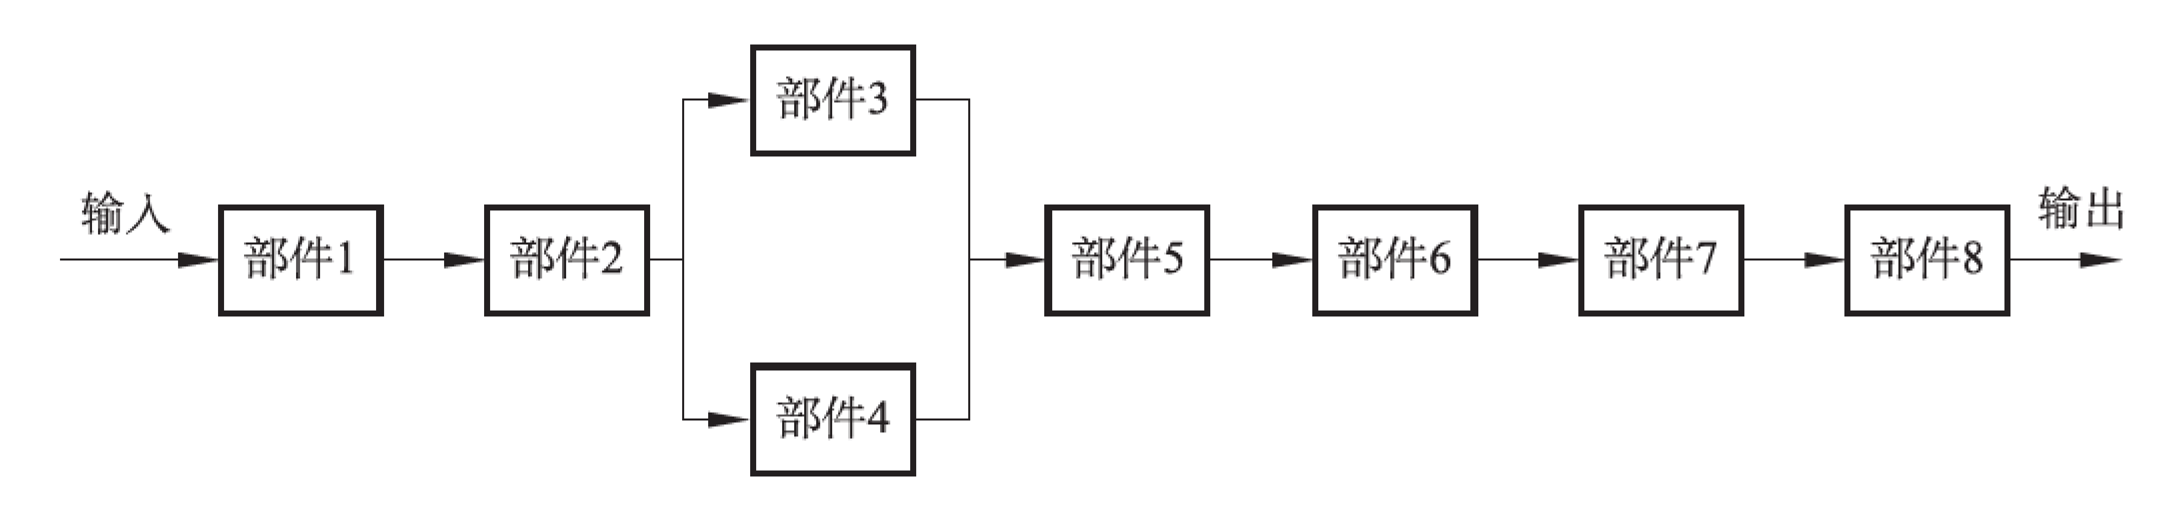


图 6-4　设备的部件拓扑结构

6.3.1　数据准备

首先，对部件进行编号，用 1 表示部件 1，以此类推。设备总共有 8 个部件组成，部件 2 的输出分为两部分，分别输送到部件 3 和部件 4，然后经过汇总，再输入到部件 5，如图 6-4 所示。

在本节中，将维护分为三种维护方式：小修、大修和置换。针对不同的部件，不同的维护方式的维护时间和维护成本是不同的，如表 6-2 和表 6-3 所示。

表 6-2　部件维修动作所需要的时间

部件编号	小修	大修	置换
1	3	11	19
2	5	13	24
3	6	15	21
4	5	14	26
5	5	12	20
6	4	16	25
7	7	17	23
8	5	12	23

表 6-3　部件维护动作的维护成本

部件编号	小修	大修	置换
1	6	14	26
2	8	16	31
3	9	18	28
4	8	17	33
5	8	14	27
6	7	19	32
7	10	20	30
8	8	15	30

设备的故障成本，是与设备的维护动作种类不相关的，是由不同的部件决定的。不同部件的故障成本如表 6-4 所示。

表 6-4 部件维护动作的故障成本

部件编号	1	2	3	4	5	6	7	8
故障成本	15	18	18	19	16	19	20	17

设备在维护调度过程中，用威布尔分布来描述设备的故障率，不同部件的不同的维护方式对应的威布尔尺度参数和形状参数是不一样的。具体的威布尔参数取值如表 6-5 所示。

表 6-5 部件维护动作的威布尔参数表

部件编号	小修参数		大修参数		置换参数	
	$\beta_{i,M}$	$\eta_{i,M}$	$\beta_{i,I}$	$\eta_{i,I}$	$\beta_{i,R}$	$\eta_{i,R}$
1	5.00	4.00	2.30	2.95	4.24	3.80
2	5.25	4.53	2.88	3.12	4.21	3.98
3	5.50	4.60	2.95	3.20	4.28	4.25
4	4.93	4.12	2.40	2.73	4.05	3.87
5	5.15	3.91	2.55	2.92	4.24	3.81
6	4.00	2.96	1.89	2.01	3.10	2.75
7	4.50	3.51	2.16	2.42	3.50	3.21
8	4.85	3.95	2.34	2.95	4.15	3.74

在本章分析的维护调度中，主要考虑设备的三种维护资源，分别是备件、维修人员和维修工具。表 6-6 列出了这三种资源的总数量。表 6-7、表 6-8 和表 6-9 分别给出了每个设备部件的小修、大修和置换所需要的每种资源的数量。

表 6-6 设备维护动作的资源总量

资源类别	备件	维修人员	维修工具
资源数量	14	13	13

表 6-7 部件执行小修维护资源

部件编号	备件	维修人员	维修工具
1	1	3	3
2	1	0	2
3	1	3	2

续表

部件编号	备件	维修人员	维修工具
4	2	2	4
5	1	4	3
6	2	3	4
7	2	2	3
8	1	3	3

表 6-8　部件执行大修维护资源

部件编号	备件	维修人员	维修工具
1	2	6	5
2	2	4	5
3	2	4	3
4	3	5	6
5	2	5	4
6	3	6	5
7	3	1	4
8	3	5	5

表 6-9　部件执行置换维护资源

部件编号	备件	维修人员	维修工具
1	4	4	6
2	4	5	6
3	5	5	6
4	5	6	7
5	3	7	6
6	4	6	7
7	5	4	7
8	6	5	6

根据图 6-3，可以计算出设备每个部件的预计停机数，如表 6-10 所示。

表 6-10　预计停机数的取值

N_i	1	2	3	4	5	6	7	8
取值	7	6	0	0	3	2	1	0

除了上述的模型输入参数，模型中的其他输入参数如表 6-11 所示。

表 6-11　其他参数的取值

参数类别	FF	FM	c_s	c_r	c_g	CA	c_q	F_M	F_I	F_R	D
参数取值	200	100	450	550	500	50	1 000	0.3	0.5	0.7	1 400

6.3.2　算法设计

首先，输入模型的参数值，包括设备的故障率，设备的维护资源数，预计停机数，每个设备部件在不同的维护动作下的衰退规律，每个设备部件在不同的维护动作下所需的各类维护资源、维护费用、维护时间、设备总运行时间、三种维护方式的维护阈值等。其次，将部件的维护记录清空，维护的标识设置为零。对于某一部件，其故障率达到了大修阈值 F_I，触发一次大修维护活动，在这次的维护过程中，故障率达到大修阈值的部件需要进行大修维护，对于其他部件，如果故障率达到小修或者更换阈值，都要进行相应维护。同时，设备的维护资源又限制了多个维护动作同时进行，设备维护费用也因为不同的维护顺序产生差异。

在模型优化求解过程中，采用遗传算法进行调度，主要步骤为：①编码部件的维护顺序，并产生初始种群；②计算父代的个体适应度值，进行选择、交叉和变异操作，计算子代个体适应度值；③用子代替代父代，继续进行遗传操作，直到达到最大进化代数；④对调度结果进行统计，绘制调度甘特图，标记设备结束一次维护活动；⑤判断当前时间是否已到设备总运行时间，如果没有到达，对设备继续进行检测是否有突发问题产生，如果有问题产生，则动态刷新资源库，如果监测部件的故障率达到维护阈值，就产生第二次维护活动，继续采用遗传算法进行模型的调度，重复这个过程，直到设备达到总的运行时间。详细的遗传算法维护调度的计算过程如图 6-5 所示。

另外，对于遗传算法的参数设定为：编码采用部件的编号进行实数编码，以设备维护调度的总费用率为适应度函数，进化种群为 30，最大遗传代数为 300，选择概率为 0.8，交叉概率为 0.8，变异概率为 0.1。

6.3.3　维护调度比较分析

首先，分析不考虑调整因子的维护调度模型的性能。参考第 5 章的比较策略，在本章中，仍然选择常见的周期维护调度作为参考策略，针对设备的整个生命周

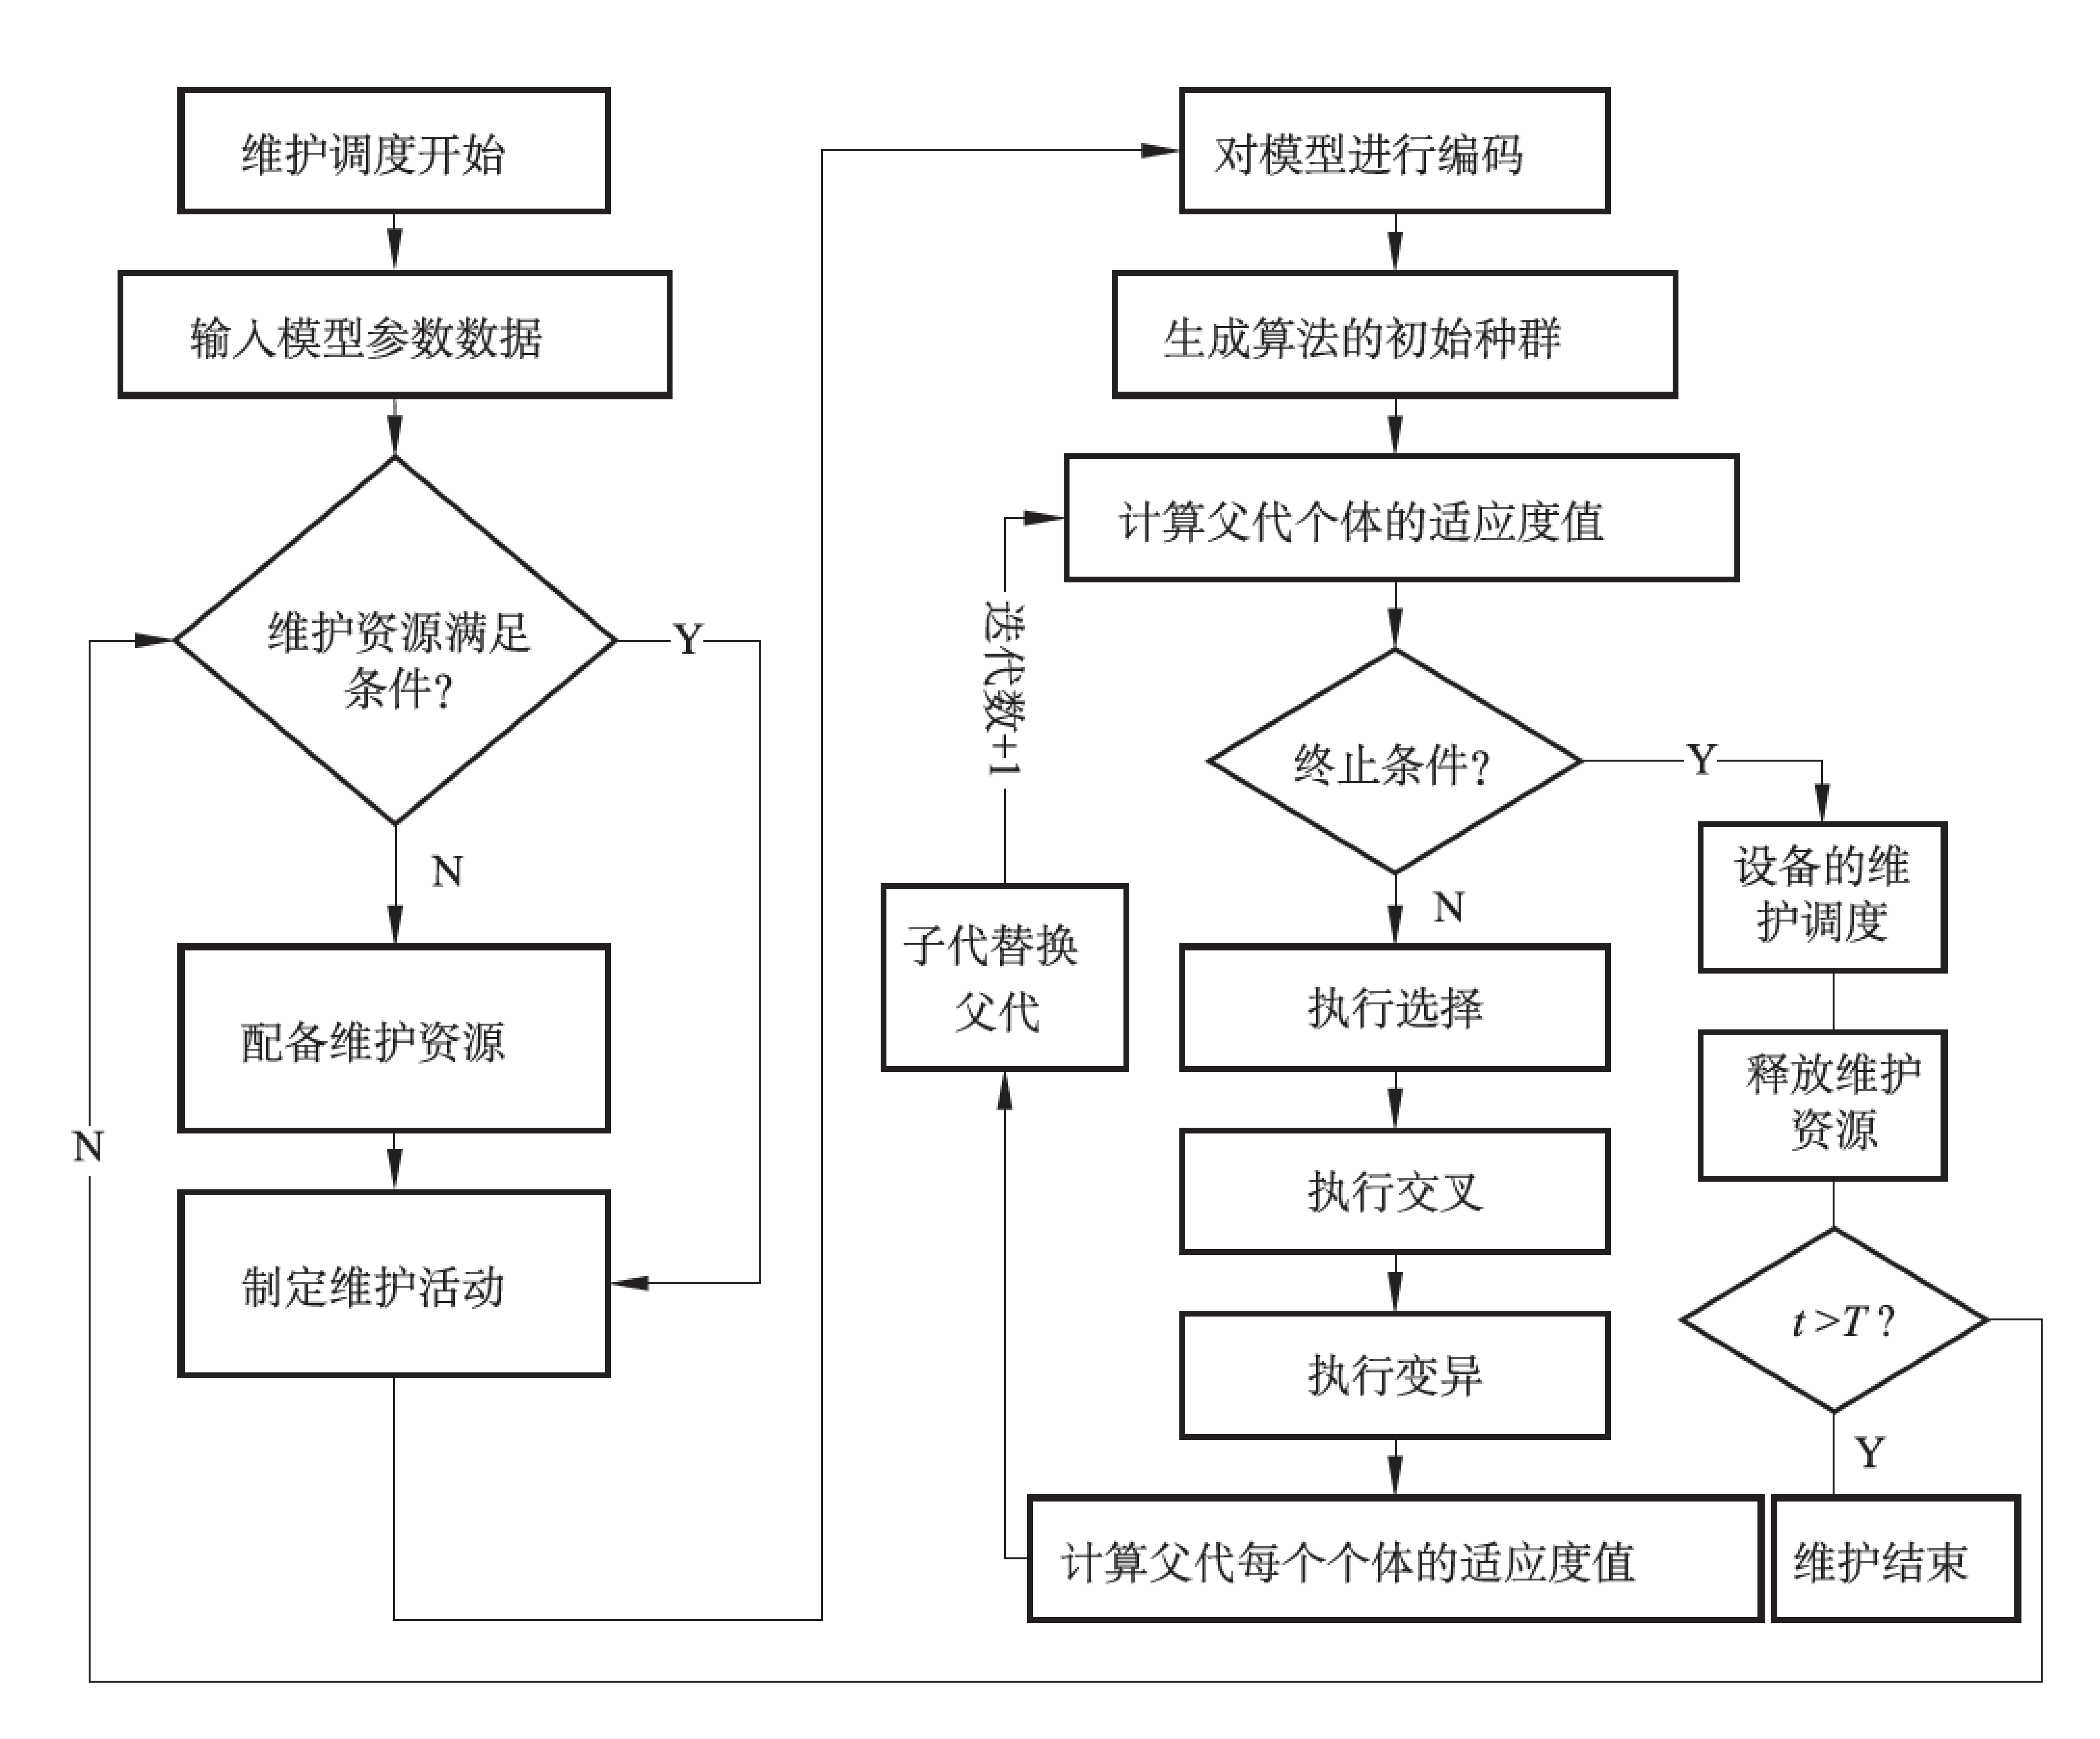


图 6-5　多部件设备的维护调度

期，将设备划分为 20 个维护周期（$T=70$），时间单位为天（d）。根据每个部件的故障率，计算得出在周期维护下，每个部件的调度情况，如表 6-12 所示。

表 6-12　周期维护调度模型的维护调度

部件编号	$M1$	$M2$	$M3$	$M4$	$M5$	$M6$	$M7$	$M8$	$M9$	$M10$
1	M			M		I		M		I
2					I		M			M
3			M		M		M		I	
4		M				I		M		M
5				M		R			M	
6	M			M		I		R		I
7			M		I			M		M
8		M			I		M		I	

续表

部件编号	M11	M12	M13	M14	M15	M16	M17	M18	M19	M20
1	M		I		M			R		M
2	I		M		M		M	I		R
3		M		I		M	M		I	
4			M		I		I			M
5	M		I		M			I		
6		M		I		R		M		I
7		R		M	I		M		R	
8	M		M	M		I		R		M

图 6-6 所示的是 4 个部件的周期维护调度情况及这四个部件的故障率变化情况，从图中可以看出，部件的故障率发展趋势是不一样的，这是因为每个设备部件自身的性能衰退是不同的，以及采取周期维护后，随着维护次数的不同，设备部件的故障率也会随之发生变化。

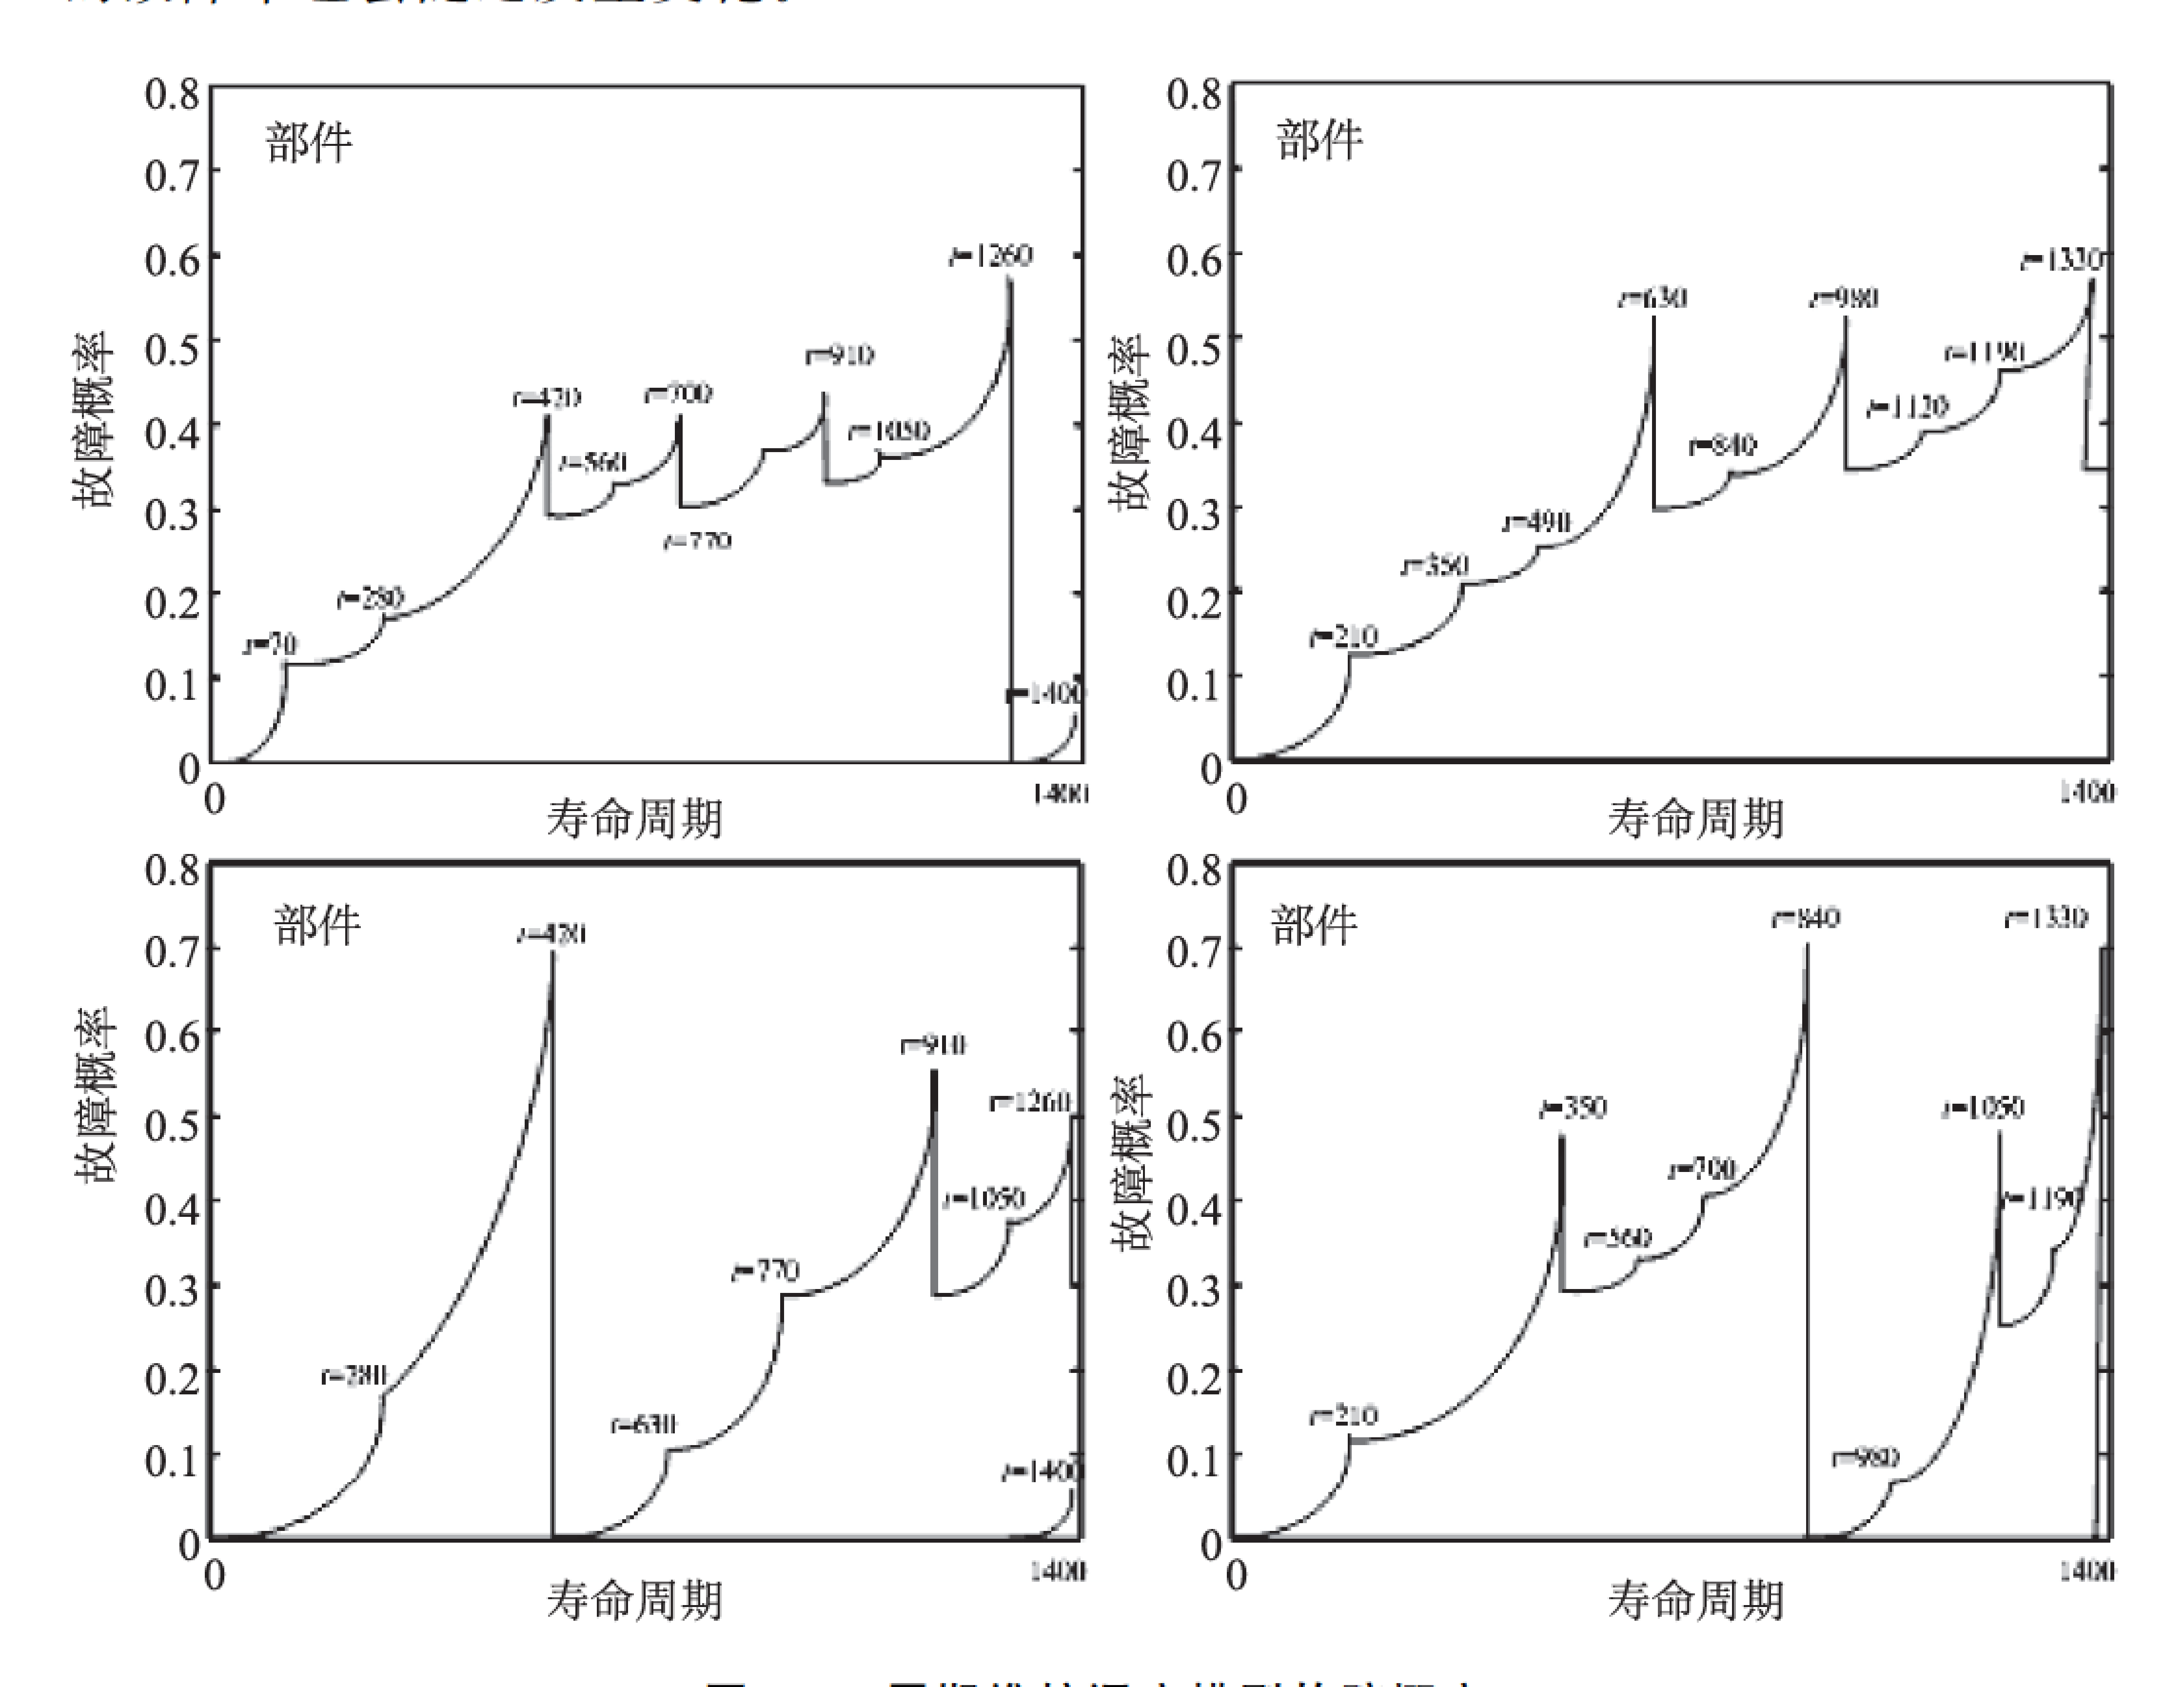


图 6-6　周期维护调度模型故障概率

根据方程(6-10)和方程(6-11),可以计算获得每个设备部件的维护调度情况,在设备的整个生命周期内,设备总共进行了10次维护活动,对于每个设备部件在这10次维护活动进行的维护调度如表6-13所示。

表6-13　维护调度模型的维护调度

部件编号	$M1$	$M2$	$M3$	$M4$	$M5$	$M6$	$M7$	$M8$	$M9$	$M10$
	$t=310$	$t=409$	$t=533$	$t=621$	$t=750$	$t=860$	$t=945$	$t=1\ 104$	$t=1\ 247$	$t=1\ 352$
1		I	M	M	I	M	M	I	M	
2		M	M	I			M	I	M	M
3		M			M	I		M		I
4		I	M	M	I	M		I	M	
5		R		M		M	M	R		M
6	R		R			R			I	M
7	M	I	M	M	R			I	M	R
8		I	M	M	I		M	I	M	I

图6-7所示的是设备中所有部件在整个生命周期内的维护情况和故障率变化情况。从图6-7中可以看出,在部件的运转过程中,每个部件的故障率的发展趋势是不同的,除了与部件自身的性能衰退有关之外,还与部件采取的维护策略有关,从而造成了每个设备部件的故障率趋势的差异,在本章提出的模型基础上,对设备进行有效的维护,可以保持设备的故障率在一个较低的水平,进而可以保证系统在长时间内稳定工作。

为了说明遗传算法的有效性,以及设备维护费用的变化情况,图6-8显示了设备第二次维护活动时,维护费用的变化情况,随着遗传算法迭代次数的增多,设备的维护费用逐渐降低,最后收敛在一个稳定的水平,得到整个设备维护费用的最优值,充分验证了遗传算法在调度过程中的有效性。

针对设备的10次维护活动,我们对设备的第二次维护活动进行详细分析,对于第二次的设备维护活动,发生在$t=409$时刻,并且,在维护活动中,对部件2、部件3采取了小修维护动作,对部件1、部件4、部件7、部件8采取了大修维护动作,对部件5采取了置换维护动作,在整个维护过程中,没有对部件6采取相应的维护动作。在系统的维护过程中,要考虑系统的维护资源,在维护资源缺少时,无法对设备进行维护,根据模型的调度结果,先对部件1、部件2和部件5采取维护动作,根据表(6-8)和表(6-9),计算部件1、部件2和部件5进行维护所需要的资源数量为[6,13,13],从而,剩余的资源数量为[9,0,0]。通过对其他部件的资源需求进行

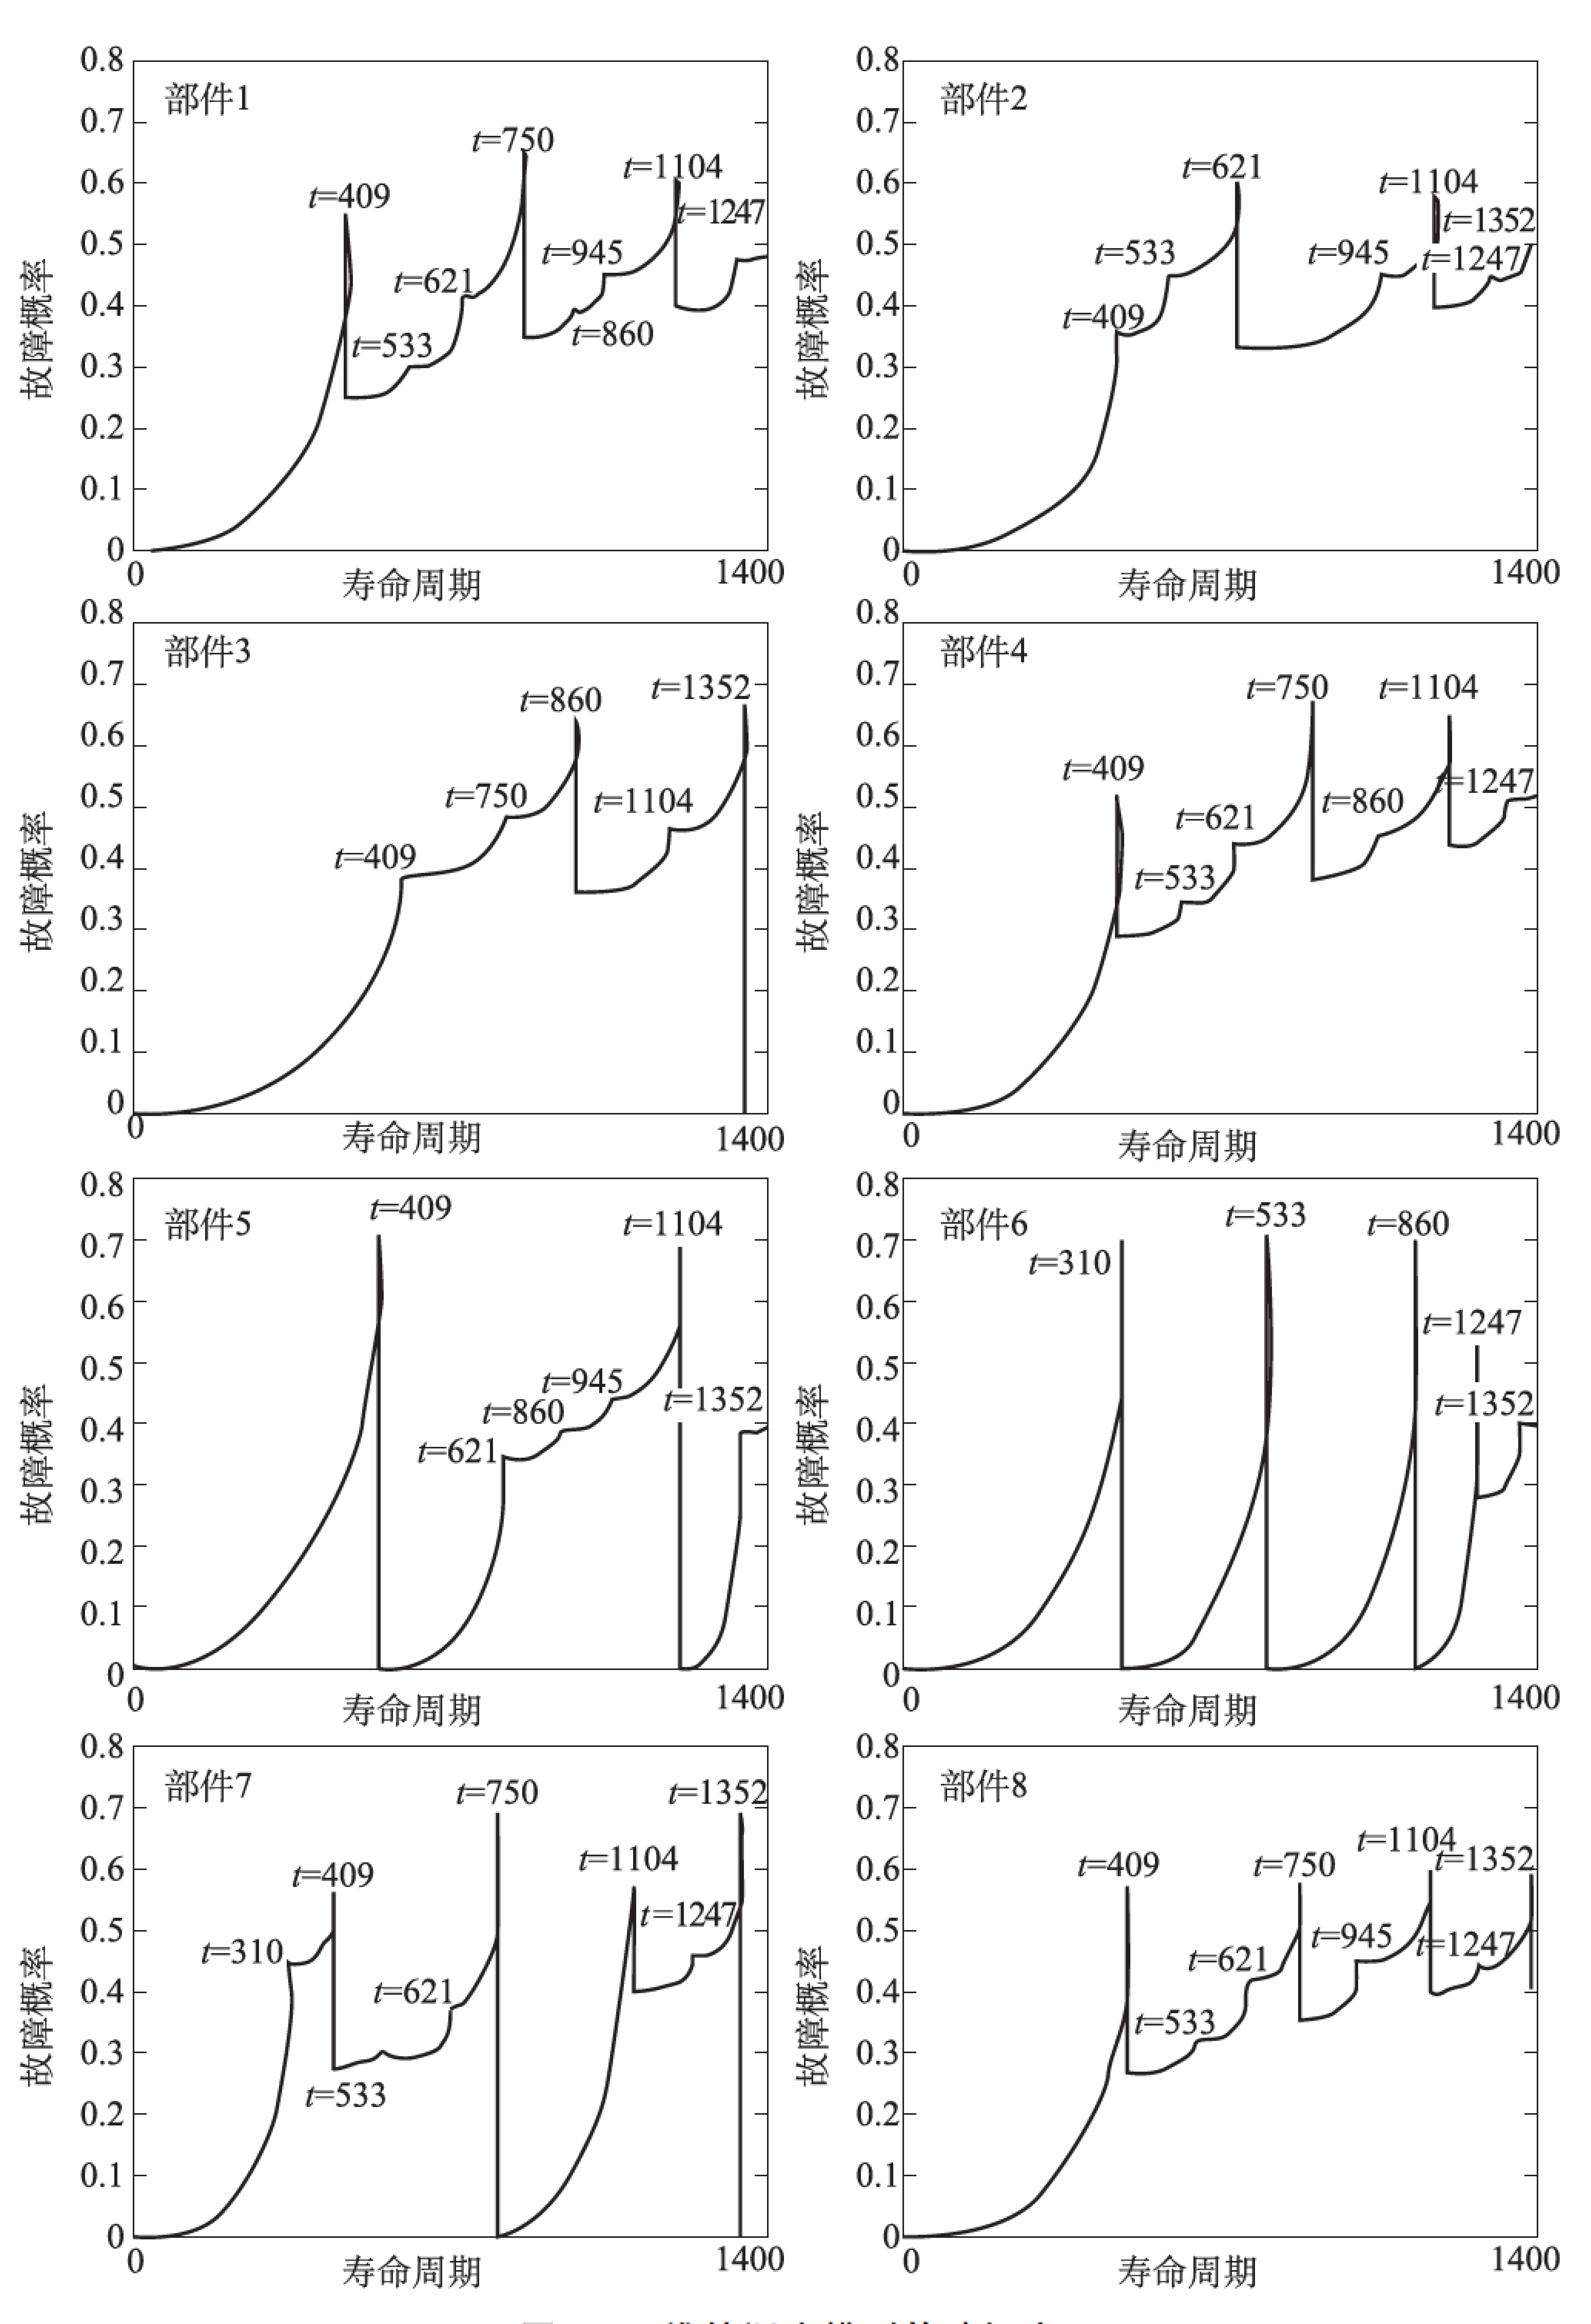


图 6-7　维护调度模型故障概率

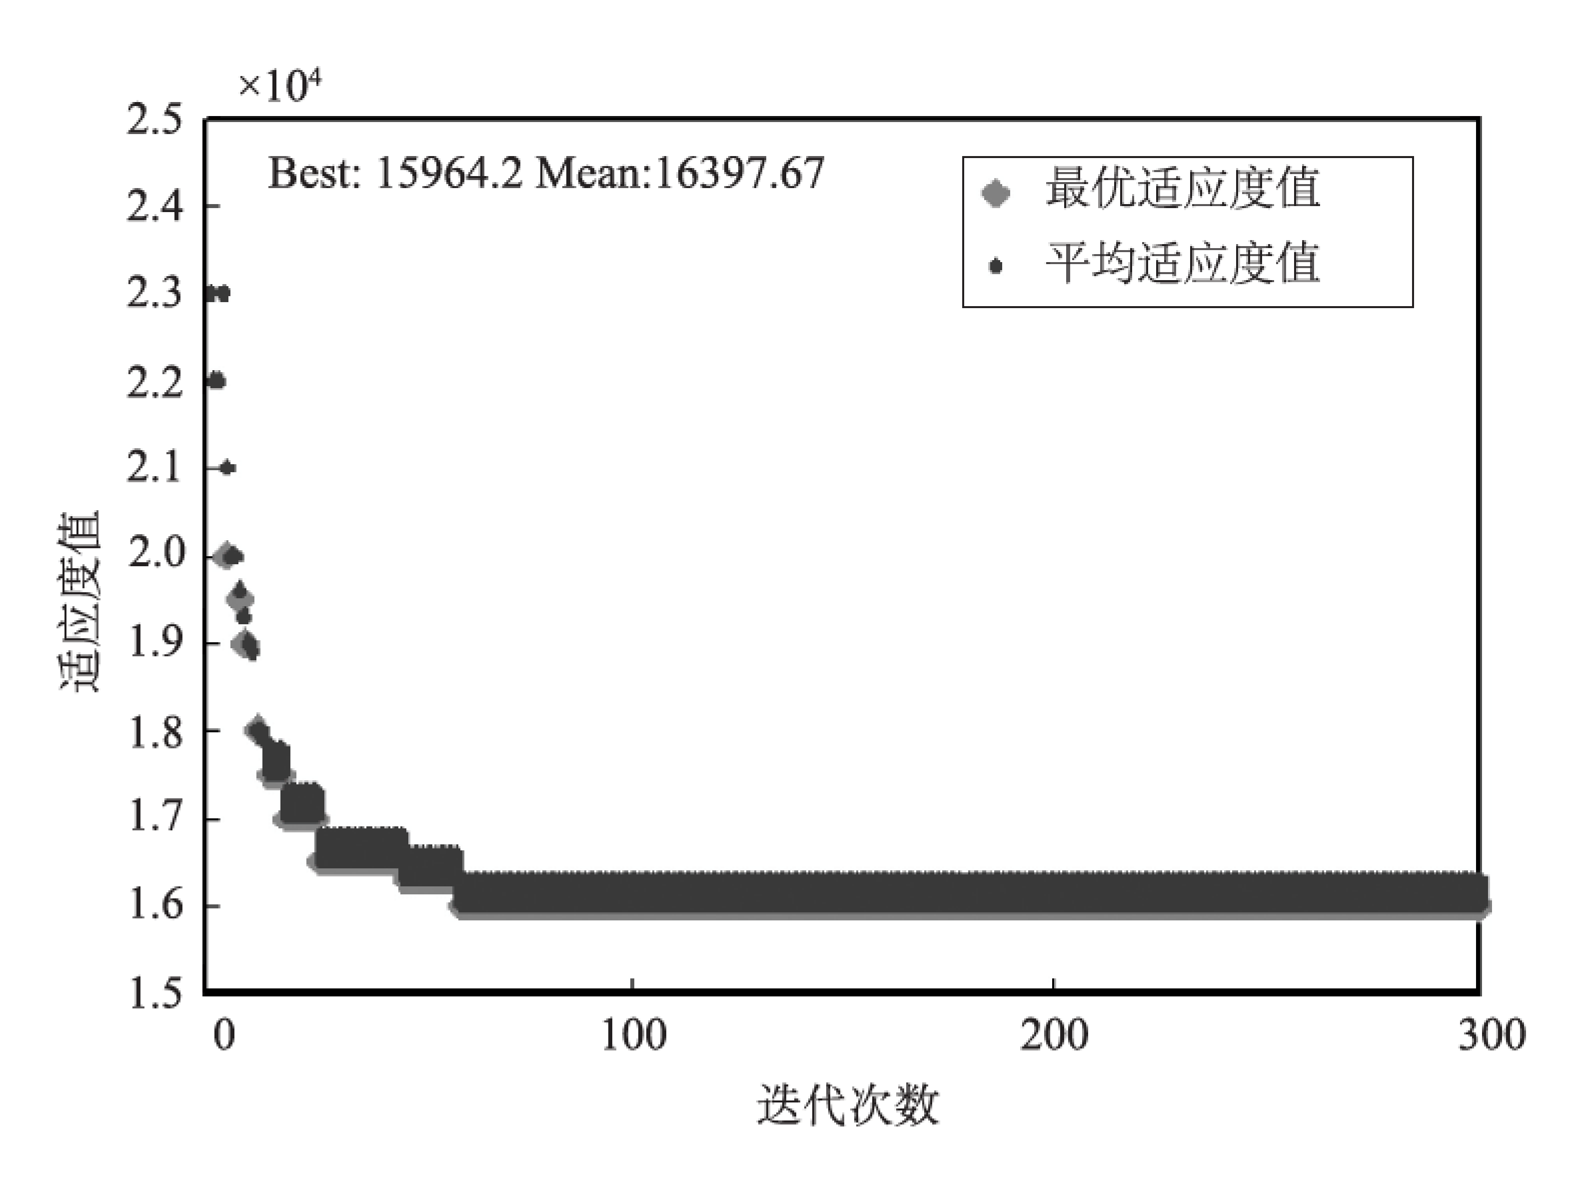


图 6-8　设备第二次维护活动的费用变化情况

分析，部件 3 的资源需求量为[1,3,2]，部件 4 的资源需求量为[3,5,6]，部件 7 的资源需求量为[3,1,4]，部件 8 的资源需求量为[3,5,5]，因此，剩余的资源数量都无法满足剩余部件的维护需求量，部件 3、部件 4、部件 7、部件 8 的维护，只能等待已经进行维护的部件维护完成后，获得维护资源，才能对部件进行维护。关于设备第二次维护调度活动的甘特图如图 6-9 所示。

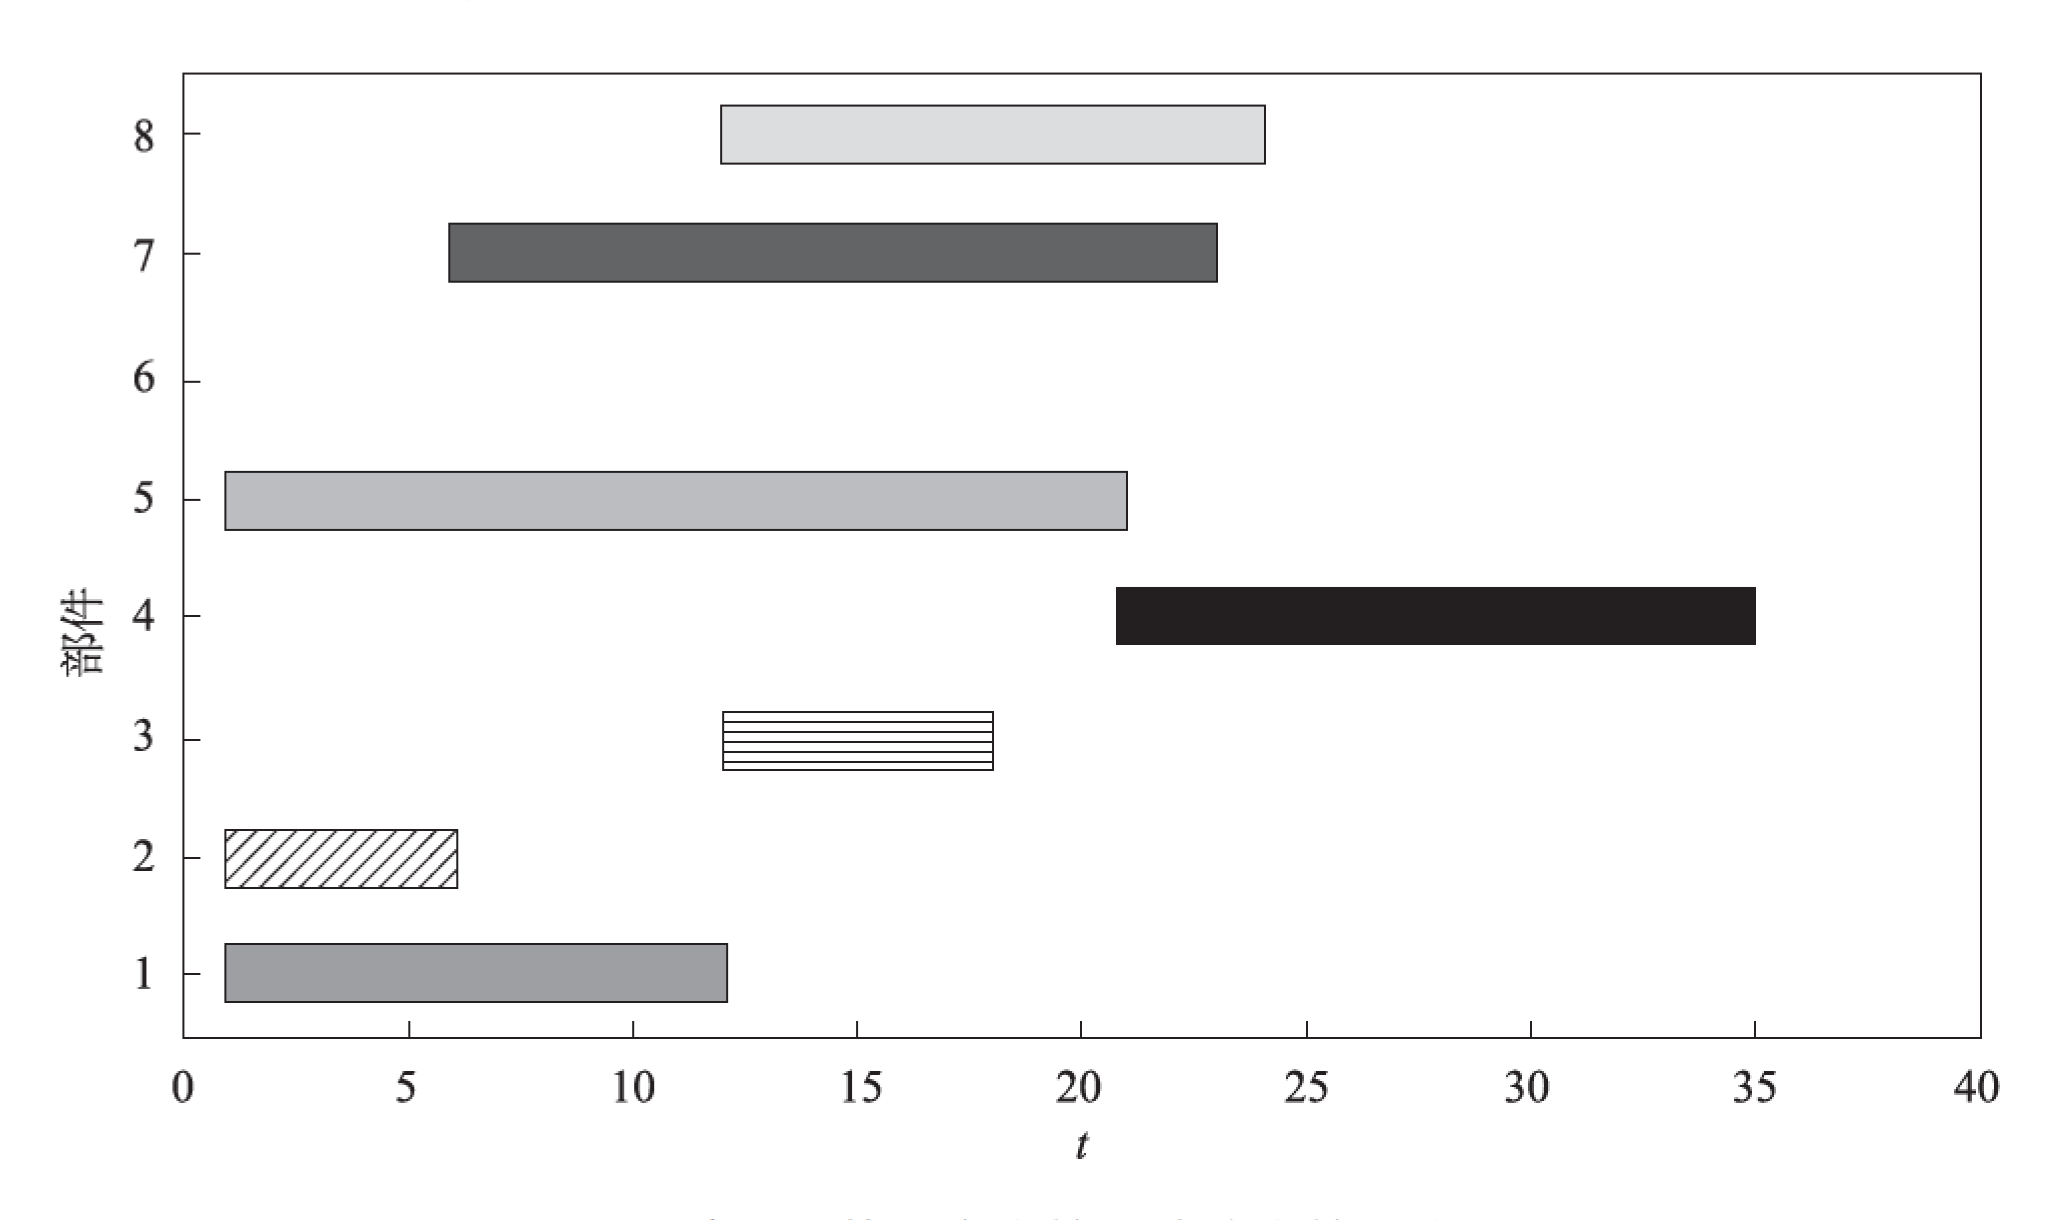


图 6-9　系统进行第二次维护活动的维护调度甘特图

最后，根据方程(6-1)、方程(6-10)和方程(6-11)，可以获得进行维护调度的总费用率为 89.21，通过周期性维护调度的设备总费用率为 109.08。

6.3.4　考虑调整因子的维护调度分析

基于方程(6-2)和方程(6-3)，分析考虑设备部件加速衰退因子和性能恢复因子的维护调度情况，其中，小修的部件加速衰退因子$\theta=0.97^{MN}$，$MN=$当前小修维护次数－1，大修的部件加速衰退因子$\theta=0.96^{MN}$，性能恢复因子$\varphi=0.97^{IN}$，$IN=$当前大修维护次数－1，通过对维护调度模型的分析，整个生命周期内，共进行了 12 次维护活动，对于每个部件在整个生命周期内所进行的维护次数如表 6-14 所示。

从表 6-14 中可以看出，除了部件 5、部件 6、部件 7 采取了置换维护动作外，剩余的部件只采取了小修和大修的维护，这些部件虽然没有进行置换维护，但是经过小修和大修维护后，这些部件的性能也相应地得到了保障，并且，对于部件 5、部件 6、部件 7，在进行置换维护后，还相应地降低了部件的小修和大修次数。这样的维护调度策略提高了设备的利用率，并且，根据部件的实际情况，采取相应的维护活动，降低了部件的故障率，延长了设备的使用时间。对于部件 1、部件 3、部件 5、部件 7，在整个维护调度过程中的故障率的变化趋势如图 6-10 所示，从图中可以出，考虑调整因子的维护调度策略，对部件进行的维护次数明显多于通过维护调度模型所获得维护策略，说明了设备部件的调整因子可以影响设备部件的维护调度。

表 6-14　维护调度模型的维护调度

部件编号	小修数	大修数	置换数
1	7	4	0
2	8	3	0
3	9	2	0
4	7	4	0
5	5	2	1
6	1	0	5
7	5	4	1
8	7	4	0

基于方程(6-2)、方程(6-3)、方程(6-10)和方程(6-11)，可以计算考虑部件调整

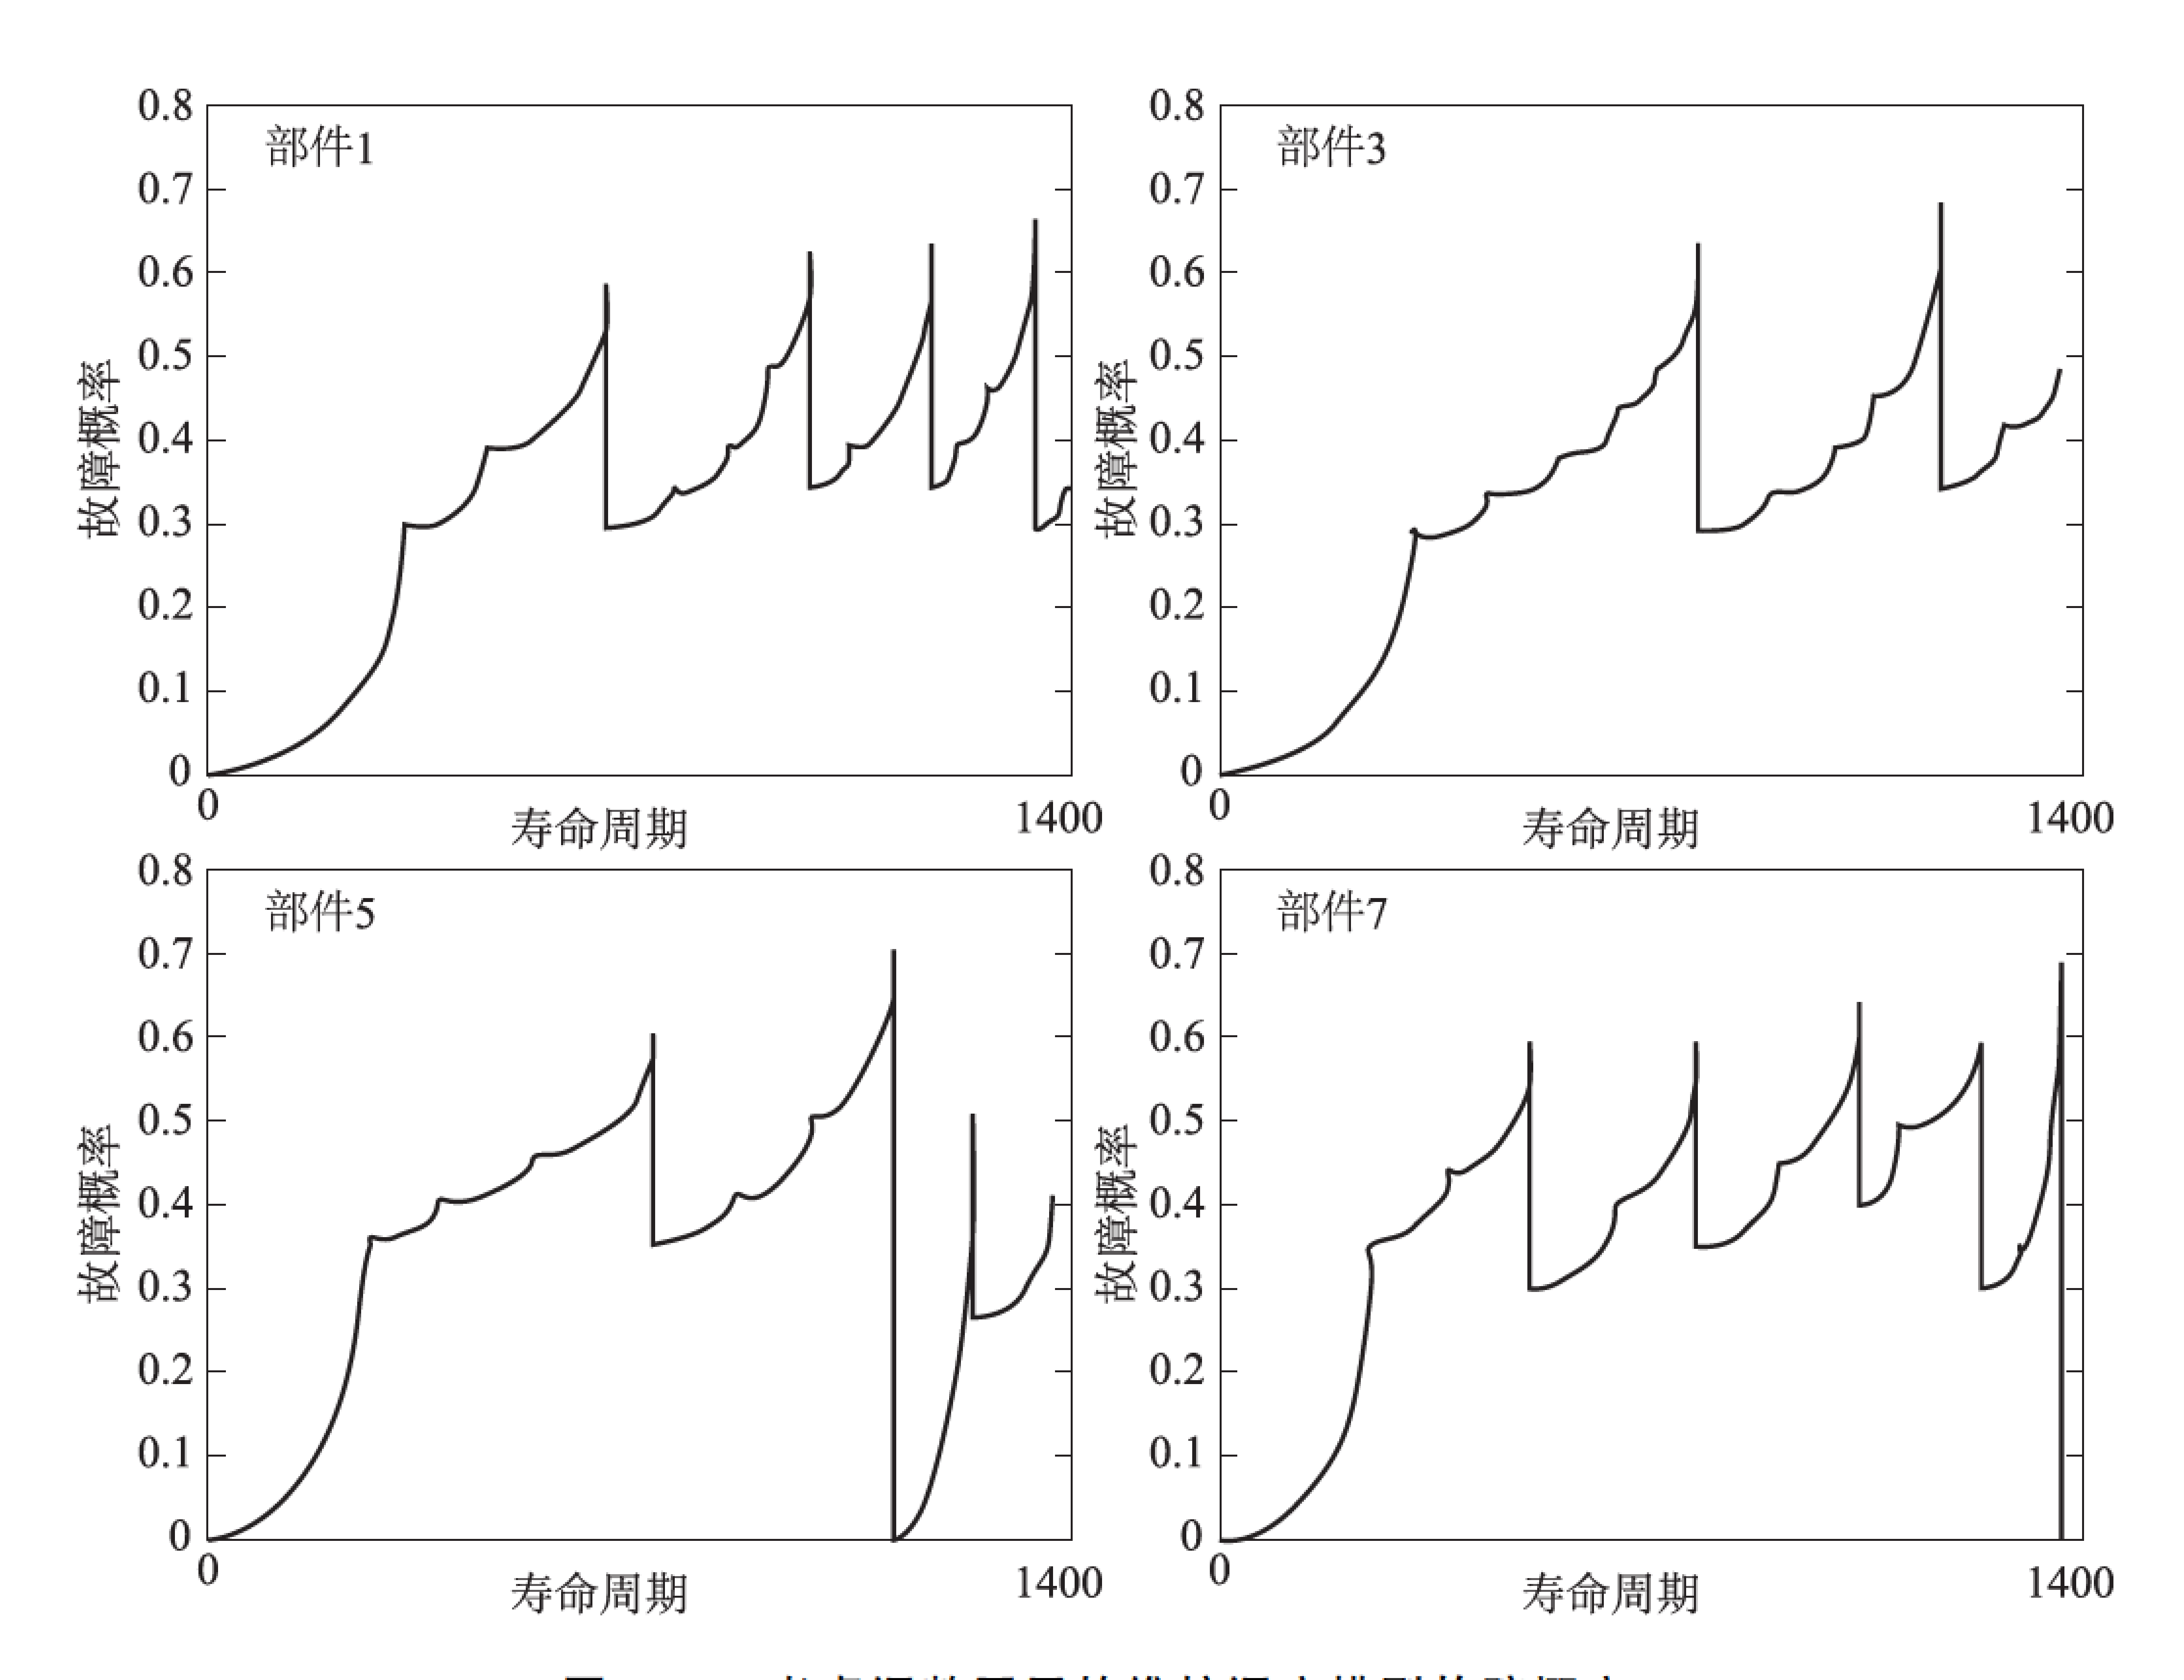


图 6-10 考虑调整因子的维护调度模型故障概率

因子的维护调度策略的总费用率为 97.79。

对于以上 3 种维护调度模型的分析，如表 6-15 所示。通过表 6-15 可以看出，虽然定期维护调度策略通过采取不同的维护动作提高了设备的利用率，但是，在设备维护调度过程中，采取的维护活动次数较多，造成了设备停机时间过长，进而损耗了高昂的设备维护成本。设备的维护调度策略不仅仅降低了设备维护调度的总费用率，还提高了设备的利用率，并且，维护活动次数较少，从而降低了设备的停机时间。因此，在设备的总费用率、维护活动次数和设备利用率方面，维护调度策略都明显优于周期维护调度策略。对于考虑设备调整因子的维护调度模型，与周期维护调度策略相比，考虑设备调整因子的维护调度策略具有低的总费用率，少的维护活动次数和高的利用率，所以说性能方面，优于周期维护调度策略。与维护调度策略相比，虽然考虑设备调整因子的维护调度策略的总费用率和维护活动的次数都高于维护调度策略，但是，提高了设备的利用率，并且考虑设备调整因子的维护调度策略更加符合设备的实际运转情况。也就是说，随着维护次数的增多，维护后

的效果也会相应地降低。

表 6-15　不同维护调度优化策略的结果比较

评估标准	维护调度模型	考虑调整因子的维护调度模型	周期维护调度策略
总费用率	89.21	97.79	109.08
维护活动次数	10	12	20
设备利用率	93.18%	97.92%	87.67%

6.4　本章小结

基于第5章提出的集成动态维护模型,考虑液压泵这一类设备的多部件特征,本章介绍了多部件设备的维护调度优化策略,考虑了设备的性能衰退、设备部件的结构相关性、设备部件间的相关关系和设备维护资源的约束,建立了设备维护调度模型和考虑设备调整因子的维护调度模型。并且,将模型应用到液压泵系统中,以周期性维护调度策略为参照策略,通过对模型的比较分析,维护调度模型在维护调度的总费用率、维护活动次数和设备的利用率等方面都优于周期性维护调度模型,并且,随着对设备维护次数的增多,维护效果会逐渐降低,考虑调整因子的维护调度模型,更加符合设备的实际情况。



7.1 结　　论

设备是现代企业制造产品的重要物质资源与保障，是企业生存和发展的基础。设备管理的水平直接影响企业的生产能力、产品质量、生产成本、劳动生产率和能源消耗等。设备管理逐渐成为企业生产管理的一个重要组成部分。现代科学生产技术的发展不仅增加了设备的机械复杂度，而且提高了生产系统的复杂性。为了解决使用先进复杂设备所带来的一系列技术、经济、管理上的新问题，解决传统设备管理的缺陷与局限性，世界上的工业发达国家逐渐提出并发展了许多新型的设备维护理论和相关支持技术。

CBM 是从众多维护理论中脱颖而出并引起了众多学者关注的维护方法，维护策略的制定建立在设备当前健康状态和未来健康状态趋势分析的基础上，以满足设备可靠性要求并以兼顾维护成本最低为目的。目前，由于工业界对预防性维护技术的需求，故障诊断领域的研究重点已逐步转向状态监测、预测性维修和故障早期诊断领域。准确并可靠的预测分析结果是成功执行基于状态的工程系统维护的关键因素，并且对安全性能的改进、任务的规划、维修时间表的制定、维修成本的降

低和停工时间的减少等都起着至关重要的作用。本书主要研究基于状态的设备维护相关技术和优化模型。在分析国际上设备健康状态预测技术的发展并结合目前设备维护的实际情况的基础上，本书以单设备系统为研究对象，通过对基于状态的设备维护优化的研究，完成以下研究内容。

1. 针对离线健康预测问题，建立单监测信息的在线健康预测模型

为了进行设备的在线健康预测，基于 HSMM 和 SMC 的联合优化，建立了一套完整的 HSMM 和 SMC 的联合优化在线健康预测模型。提出了一种联合多步向前健康识别算法，用于在线识别设备健康状态，并且，将在线识别的健康状态用作健康预测的分析基础和依据，提出了在线剩余寿命预测模型。当前，单一的方法、模型、算法很难满足设备的在线健康预测，本书提出的联合模型，是基于 HSMM 丰富的数学结构和 SMC 的在线特征而来的，利用设备的健康预测对其性能状态进行量化，进而描述设备的实际运行状况。

为了说明方法的有效性，对提出的在线健康预测方法进行验证，验证结果显示提出的方法很好地描述了设备的健康变化情况。并且与一步向前识别算法、多步向前识别算法和 HSMM 进行了比较分析，验证了该方法在单监测信息在线健康预测方面的有效性和准确性，也为后续内容的发展，提供了分析依据和基础。

2. 针对单监测信息健康预测方法，建立多监测信息的在线健康预测模型

为了更好地提高在线健康预测的精确度，基于单监测信息在线健康预测方法的思想，提出了多监测信息的在线健康预测方法。为了处理多监测信息和降低模型的计算复杂性，对 HSMM 的基本算法进行了修正，提出了修正的前向—后向算法、Viterbi 算法和 Baum-Welch 算法，计算复杂性从 $O\left((MD+M^2)T\right)$ 降低到 $O\left((D+M^2)T\right)$。建立了自适应隐式半马尔可夫模型，来处理多监测信息的在线健康预测问题，应用最大似然线性回归训练对输出概率分布和驻留概率分布进行自适应训练，处理多监测信息之间的差异性。结合修正的 HSMM，进行有效的多监测信息在线健康预测。在此基础上，提出多监测信息的在线剩余寿命预测方法。

为了说明方法的有效性，对提出的多监测信息在线健康预测方法进行验证，根据验证分析可知，多监测信息的在线健康预测与单监测信息在线健康预测相比，在设备健康状态识别、诊断、预测和计算复杂性方面，具有更好的有效性和准确性，也为后续维护的发展，提供了基础。

3. 针对传统的维护方式，建立基于在线健康预测的集成动态维护模型

首先，针对传统的设备维护模型，集成维护考虑了设备的衰退性能（设备的退

化和老化信息),结合了设备的诊断信息和预测信息,以总的维护成本(故障成本、维护成本和资源成本)和总维护时间为目标,提出了基于在线健康预测的集成动态维护模型,建立了两层集成动态维护模型,实行分阶段的动态维护。

其次,在传统的维护模型中,设备的维护资源只考虑了备件的约束条件,本书中,同时考虑了备件和维修人员的双约束条件。并且,针对小修和大修的维护方式,引入了维护风险影响,将维护风险因子集成到动态维护模型。

最后,对模型进行验证,根据验证分析可知,提出的集成动态维护模型,与定期维护模型和纯动态维护策略相比,具有更好的有效性和准确性,也为后续多部件设备维护的拓展,提供了基础。

4. 针对系统的维护策略,建立基于集成维护模型的维护调度优化模型

基于集成动态维护模型,针对多部件设备的特点,建立多部件设备的维护拓展模型。多部件设备的维护决策包括性能衰退、维护方式和维护费用三部分。在性能衰退方面,通过在线诊断信息和预测信息得到设备故障率变化趋势,用威布尔分布模拟设备的衰退过程;在维护方式方面,定义小修、大修和更换三种维护方式,分别描述了三种维护方式对设备故障率的影响;在维护费用方面,考虑了故障成本、维护成本、资源成本和停机成本四部分,根据每次维护活动的费用模型,建立了多阶段的总费用率模型。

为了说明维护拓展模型的有效性,对提出的维护调度优化模型进行验证,根据验证分析可知,提出的多部件设备维护调度优化模型,与周期性维护调度优化模型相比,在总费用率、生命周期维护活动次数和设备利用率方面,具有很好的性能和有效性。

7.2 展　　望

本研究开展设备健康预测、设备维护优化研究,提出和拓展了一些设备健康预测方法、设备维护策略方法,是设备维护领域内的前沿或热点问题,既具有较高的研究价值,也具有很好的扩展性,可从以下几方面进一步深入研究。

(1) 本研究讨论的在线健康预测模型,随着在线监测数据的增多,需要改进目

前的在线健康预测方法，将其优化到适应大数据的健康预测领域。

（2）本研究中多监测信息的 AHSMM 是基于设备工作负荷稳定的基础上的，将设备的失效率结合到设备的健康预测模型。对于进一步的工作，部分失效率的模型可以被考虑结合到健康预测模型中，考虑设备的变动工作负荷及条件。

（3）本研究提出的基于设备性能衰退和维护风险的集成动态维护模型体现了良好的性能，针对将来更复杂的制造设备，可以考虑对维护模型进一步精确和优化。针对目前的维护资源只考虑了备件和维修人员，可以将维护资源约束进一步进行扩展，包括设备的维护工具和维护能源等。

（4）本研究建立了多部件设备的维护调度优化模型，并且具有很好的性能，但是，针对多部件设备与生产之间的关系，还需要进一步的丰富。另外，这类问题属于 NP 问题，求解模型需要借助启发式算法的优化，因此，在求解模型的算法上可以做进一步的研究。



[1] 潘家轺．现代生产管理学[M]. 北京:清华大学出版社,2004.

[2] Heng,A.,Zhang,S.,Tan,A. C. C. et al.. Rotating machinery prognostics:state of the art,challenges and opportunities [J]. Mechanical Systems and Signal Processing,2009,23(3):724-739.

[3] 赵艳萍,姚冠新,陈骏．设备管理与维修[M]. 北京:化学工业出版社,2004.

[4] 吕文元．先进制造设备维修理论、模型与方法[M]. 北京:科学出版社,2008.

[5] Nandi,S.,Toliyat,H. A.. Condition monitoring and fault diagnostic of electrical machines-A review [C]. In:Thirty-Fourth IAS Annual Meeting,Phoenix,AZ,USA,1999,1:197-204.

[6] 石馨．医疗设备的监管与维护及其意义和价值[J]. 医疗设备信息,2010,31(7):97-99.

[7] Bocchini,P.,Frangopol,D. M.. A probabilistic computational framework for bridge network optimal maintenance scheduling [J]. Reliability Engineering and System Safety,2011,96(2):332-349.

[8] Wrom,J. M.,Harten,A. V.. Model based decision support for planning of road maintenance[J]. Reliability Engineering and System Safety,1996,51(3):305-316.

[9] Jin,D.,Powell,H. L. K.. Optimal fleet utilization and replacement [J]. Transportation research Part E,Logistics and Transportation Review,2000,36(1):3-20.

[10] Barlow,R. E.,Hunter,L. C.. Optimum preventive maintenance policies[J]. Operation Research,1960,8(1):90-100.

[11] 王维德．21 世纪的设备维修方式[M]. 国外黄金参考,1999,5(6):6-12.

[12] 郭韬红．设备维修制度的探讨[J]. 铁路货运,2000,5:31-33.

[13] Martin, K. F.. A review by discussion of condition monitoring and fault-diagnosis in machine-tools[J]. International Journal of Machine Tools and Manufacture, 1994, 34:527-551.

[14] Katipamula, S., Brambley, M. R.. Methods for fault detection, diagnostics, and prognostics for building systems-a review[J]. Part I, HVAC&R RESEARCH, 2005, 11(1):3-25.

[15] Jardine, A. K. S., Daming, L., Dragan, B.. A review on machinery diagnostics and prognostics implementing condition-based maintenance[J]. Mechanical Systems and Signal Processing, 2006, 20:1483-1510.

[16] Schwabacher, M., Goebel, K.. A survey of artificial intelligence for prognostics[J]. AAAI Fall Symposium- Technical Report, 2005:107-114.

[17] Zhang, L., Li, X. S.. A review of fault prognostics in condition based maintenance[C]. Sixth International Symposium on Instrumentation and Control Technology: Signal Analysis, Measurement Theory, Photo-Electronic Technology, and Artificial Intelligence, Oct 13-15 2006, Beijing, China, vol. 6357, 2006, art. no. 635752.

[18] Kothamasu, R., Huang, S. H.. VerDuin, W. H., System health monitoring and prognostics - a review of current paradigms and practices[J]. International Journal of Advanced Manufacturing Technology, 2006, 28:1012-1024.

[19] Goh, K. M., Tjahj, B., Baines, T., Subramaniam, S.. A review of research in manufacturing prognostics[C]. 2006 IEEE International Conference on Industry, Aug. 16-18 2006, Singapore, 2006, 16-18:417-422.

[20] Glodez, S., Sraml, M., Kramberger, J. A.. Computational model for determination of service life of gears [J]. International Journal of Fatigue, 2002, 24(10):1013-1020.

[21] Ray, A., Tangirala, S.. Stochastic modeling of fatigue crack dynamics for on-line failure prognostics [J]. IEEE Transactions on Control System Technology, 1996, 4(4):443-451.

[22] Wang, W.. Towards dynamic model-based prognostics for transmission gears [C]. Proceedings of SPIE, 2002:157-167.

[23] Oppenheimer, C. H., Loparo, K. A.. Physically based diagnosis and prognosis of cracked rotor shafts [C]. Proceedings of SPIE, 2002:122-132.

[24] Li, C. J., Lee, H.. Gear fatigue crack prognosis using embedded model, gear dynamic model and facture mechanics [J]. Mechanical Systems and Signal Processing, 2005, 19(4):836-846.

[25] Kacprzynskl, G. J., Sarlashkar, A., Roemer, M. J., etc.. Predicting remaining life by fusing the physics of failure modeling with diagnostics [J]. JOM, 2004, 56(3):29-35.

[26] Li, Y., Billington, S., Zhang, C., etc.. Adaptive prognostics for rolling element bearing condition [J]. Mechanical Systems and Signal Processing, 1999, 13(1):103-113.

[27] Li,Y. ,Kurfeess T. R. ,Liang,S. Y.. Stochastic prognostics for rolling element bearings [J]. Mechanical Systems and Signal Processing,2000,14(5):747-762.

[28] Chelidze,D. ,Cusumano,J. P. ,Chatterjee,A.. A dynamical systems approach to damage evolution tracking,part 1:description and experimental application [J]. Journal of Vibration and Acoustics,2002,124(2):250-257.

[29] Cusumano,J. P. ,Chelidze,D. ,Chatterjee,A.. A dynamical systems approach to damage evolution tracking,part 2:model-based validation and physical interpretation [J]. Journal of Vibration and Acoustics,2002,124(2):258-264.

[30] Chelidze,D.. A dynamic systems approach to failure prognosis [J]. Journal of Vibration and Acoustics,2004,126(1):2-8.

[31] Luo,J. ,Pattipati,K. R. ,Qiao,L. ,etc.. Model-based prognostic techniques applied to a suspension system [J]. IEEE Transactions on Systems,Man,and Cybernetics-Part A:Systems and Humans,2008,38(5):1156-1168.

[32] Orsagh,R. F. ,Sheldon,J. ,Klenke C. J.. Prognostics/Diagnostics for gas turbine engine bearings [C]. Proceedings of the 2003 IEEE Aerospace Conference,2003:159-167.

[33] Marble,S. ,Morton,B. P.. Predicting the remaining life of propulsion system bearings [C]. Proceedings of the 2006 IEEE Aerospace Conference,2006:1-8.

[34] Qiu,J.. Damage mechanics approach for bearing lifetime prognostics [J]. Mechanical Systems and Signal Processing,2002,16(5):817-829.

[35] Ramakrishnan,A. ,Pecht,M. G.. A life consumption monitoring methodology for electronic systems [J]. IEEE Transactions on Components and Packaging Technologies,2003,26(3):625-634.

[36] Gu,J. ,Barker,D. ,Pecht,M.. Prognostics implementation of electronics under vibration loading [J]. Microelectronics Reliability,2007,47(12):1849-1856.

[37] Musallam,M. ,Johnson,C. M. ,Yu,C. ,etc.. In-service life consumption estimation in power modules [C]. 13th International Power Electronics and Motion Control Conference,2008:76-83.

[38] Ompusunggu,A. P. ,Papy,J. M. ,Vandenplas,S. ,etc.. A novel monitoring method of wet friction clutches based on the post-lockup torsional vibration signal [J]. Mechanical Systems and Signal Processing,2013,35:345-368.

[39] Cong,F. Y. ,Chen,J. ,Dong,G. M. ,Pecht,M.. Vibration model of rolling element bearings in a rotor-bearing system for fault diagnosis [J]. Journal of Sound and Vibration,2013,332:2081-2097.

[40] Bonfa,I. ,Maioli,C. ,Sarti,F. ,Milandri,G. L.. Dal Monte,HERMES:an expert system

for the prognosis of hepatic diseases[J]. Artificial Neural Networks and Expert Systems, 1993. Proceedings, Nov 1993, 240-246.

[41] Sottile, J., Kohler, J. L.. Techniques for Improved Predictive Maintenance Testing of Industrial Power Systems[J]. IEEE Trans. on Industn Applications. vol. 25(6), Nov./Dec. 1999, 992-999.

[42] Garga, A. K., McClintic, K. T., Campbell, R. L., Yang, C. C., Lebold, M. S., Hay, T. A., Byington, C. S.. Hybrid reasoning for prognostic learning in CBM systems[C]. Proceedings of the IEEE Aerospace Conference, Mar 10-17 2001, Big Sky, MT, United States, 2001, 6:2957-2969.

[43] David, J. M., Krivine, J. P.. Three artificial intelligence issues in fault diagnosis: declarative programming, expert systems, and model-based reasoning[J]. Proceedings of the Second European Workshop on Fault Diagnostics, Reliability and Related Knowledge Based Approaches, 1987, 6-8:190-196.

[44] Lembessis, E., Antonopoulos, G., King, R. E., Halatsis, C., Torres, J.. "CASSANDRA": an on-line expert system for fault prognosis[C]. Proceedings of the 5th CIM Europe Conference, 1989, 371-377.

[45] Butler, K. L., An expert system based framework for an incipient failure detection and predictive maintenance system[C]. Proceedings of the International Conference on Intelligent Systems Applications to Power Systems, ISAP, Jan 28-Feb 2 1996, Orlando, FL, United States, 1996: 321-326.

[46] Biagetti, T., Sciubba. E.. Automatic diagnostics and prognostics of energy conversion processes via knowledge based systems[J]. Energy, 2004, 29(12-15):2553-2572.

[47] Wang, Q., Zhang, J., Qin, J. Z.. The modeling method study of fault fuzzy forecast system[J]. Computer Measurement and Control, 2002, 10(1):23-25.

[48] Ma, J., Chen, S., Xu, Y.. Fuzzy logic from the viewpoint of machine intelligence[J]. Fuzzy Sets and Systems, 2006, 157(5):628-634.

[49] Zadeh, L. A.. The role of fuzzy logic in the management of uncertainty in expert systems[J]. Fuzzy Sets and Systems, 1983, 11(1):197-198.

[50] Choi, S. S., Kang, K. S., Kim, H. G., Chang, S. H.. Development of an on-line fuzzy expert system for integrated alarm processing in nuclear power plants[J]. IEEE Transactions on Nuclear Science, 1995, 42(4):1406-1418.

[51] Frelicot, C., A fuzzy-based prognostic adaptive system[J]. RAIRO-APII-JESA Journal Europeen des Systemes Automatises, 1996, 30(2-3):281-299.

[52] 宋云雪,史永胜. 基于模糊自组织映射神经网络的故障诊断方法[J]. 计算机工程, 2003, 29(14):98-99.

[53] 鞠可一，葛世伦．基于数据挖掘技术创建企业本体[J]. 微计算机信息，2006，22：228-230.

[54] Wang，Z. Q. ，Wang，W. B. ，Hu，C. H. ，Si，X. S. ，Zhang，W. . A Prognostic Information-Based Order-Replacement Policy for a Non-Repairable Critical System in Service [J]. IEEE Transactions on Reliability，2015，64(2)：721-728.

[55] Orchard，M. E. ，Vachtsevanos，G. J. . A particle filtering approach for on-line failure prognosis in a planetary carrier plate [J]. International Journal of Fuzzy Logic and Intelligent Systems，2007，7(4)：221-227.

[56] Cheng，S. ，Pecht，M. . A fusion method for remaining useful life prediction of electronic products [C]. 2009 IEEE International Conference on Automation Science and Engineering，2009：102-107.

[57] Stanek，M. ，Morari，M. ，Frohlich，K. . Model-aided diagnosis：An inexpensive combination of model-based and case-based condition assessment [J]. IEEE Transactions on Systems，Man and Cybernetics-Part C：Applications and Reviews，2001，31：137-145.

[58] Tsoukalas，L. H. ，Uhrig，R. E. . Fuzzy and neural approaches in engineering[M]. New York，Wiley，1997.

[59] Lu，C. ，Yuan，H. ，Ma，J. . Fault detection，diagnosis，and performance assessment scheme for multiple redundancy aileron actuator [J]. Mechanical Systems and Signal Processing，February 16，2016：1-23，Article in Press.

[60] 李战芬，韩意，刘彦臣，樊孝仁．基于神经网络遗传算法优化的曲轴疲劳寿命预测[J]. 中北大学学报(自然科学版)，2016，(04)：401-406.

[61] Connor，J. T. ，Matinem，R. D. ，Atlas，L. E. . Recurrent neutral networks and robust time series prediction[J]. IEEE Transactions on Neural Networks，1994，5：240-254.

[62] 张志明，程惠涛，徐鸿．神经网络组合预报模型及其在汽轮发电机组状态检修中的应用[J]. 中国电机工程学报，vol. 23(9)，2003，204-205.

[63] 路志英，赵智超，郝为．基于人工神经网络的多模型综合预报方法[J]. 计算机应用，vol. 24(4)，2007，50-51.

[64] Spoerre，J. K. . Application of the cascade correlation algorithm(CCA) to bearing fault classification problems [J]. Computers in Industry，1997，32：295-304.

[65] Wang，W. ，Yao，M. ，Wu，Y. ，Wu，Q. . Hybrid flow-shop scheduling approach based on genetic algorithm [J]. Journal of System Simulation，2002，14(7)：863-865.

[66] Tallam，R. M. ，Habetler，T. G. ，Harley，R. G. . Self-commissioning training algorithms for neural networks with applications to electric machine fault diagnostics [J]. IEEE Transactions on Power Electronics，2002，17：1089-1095.

[67] Sohn, H. , Worden, K. , Farrar, C. R. . Statistical damage classification under changing environment and operational conditions [J]. Journal of Intelligent Material Systems and Structures, 2002, 13: 561-574.

[68] Chinnam, R. B. , Baruah, P. . A neuro-fuzzy approach for estimating mean residual life in condition-based maintenance systems [J]. International Journal of Materials and Product Technology, 2004, 20(1-3): 166-179.

[69] Gebraeel, N. Z. , Lawley, M. , Liu, R. , etc. . Residual life predictions from vibration-based degradation signals: a neural network approach [J]. IEEE Transactions on Industrial Electronics, 2004, 51(3): 694-700.

[70] Tran, V. T. , Yang, B. S. . Machine condition prognosis using multi-step ahead prediction and neuro-fuzzy systems [C]. International symposium on advanced mechanical and power engineering, 2008: 169-174.

[71] Leu, S. S. , Tri, J. W. A. . Probabilistic prediction of tunnel geology using a Hybrid Neural-HMM[J]. Engineering Applications of Artificial Intelligence, 2011, 24: 658-665.

[72] Li, D. Z. , Wang, W. , Ismail, F. . Enhanced fuzzy-filtered neural networks for material fatigue prognosis [J]. Applied Soft Computing, 2013, 13: 283-291.

[73] Sadough Vanini, Z. N. , Khorasani, K. , Meskin, N. . Fault detection and isolation of a dual spool gas turbine engine using dynamic neural networks and multiple model approach [J]. Information Sciences, 2013, Article in Press.

[74] Ahmadzadeh, F. , Lundberg, J. . Remaining useful life prediction of grinding mill liners using an artificial neural network [J]. Minerals Engineering, 2013, 53: 1-8.

[75] Baraldi, P. , Compare, M. , Sauco, S. , Zio, E. . Ensemble neural network-based particle filtering for prognostics [J]. Mechanical Systems and Signal Processing, 2013, Article in Press.

[76] 陈仲生，杨拥民，胡政．基于周期时变 AR 模型的故障早期预报[J]，机械工程学报，2005, 41(1): 184-188.

[77] Banakar, A. , Azeem, M. F. . Artificial wavelet neutral network and its application in neuro-fuzzy models[J]. Applied Soft Computing, 2008, 8(4): 1463-1485.

[78] Szu, H. , Telfer, B. , Garcia, J. . Wavelet transforms and neutral network for compression and recognition[J]. Neutral networks, 1996, 9(4): 695-708.

[79] Vachtsevanos, G. , Wang P. . Fault prognosis using dynamic wavelet neural networks [C]. AUTOTESTCON(Proceedings), 2001: 857-870.

[80] Wang, P. , Vachtsevanos, G. . Fault prognostics using dynamic wavelet neural networks [J]. Artificial Intelligence for Engineering Design, Analysis and Manufacturing, 2001, 15(4): 349-365.

[81] Gebraeel, N. Z., Lawley, M. A.. A neural network degradation model for computing and updating residual life distributions[J]. IEEE Transactions on Automation Science and Engineering, 2008, 5(1): 387-401.

[82] Antonio, F. C., Mira, J., Miguel A., Ana, E. D.. On motion detection through a multi-layer neural network architecture[J]. Neutral networks, 2003, 16(2): 205-222.

[83] Parker, B. E., Nigro, T. M., Carley, M. P., Barron, R. L., Ward, D. G., Poor, H. V., Rock, D.. Helicopter gearbox diagnostics and prognostics using vibration signature analysis[C]. Proceedings of the SPIE-The International Society for Optical Engineering, April 13 1993, Orlando, FL, United States, 1993, 1965: 531-542.

[84] Kohonen, T.. Self-Organizing Maps[M]. Springer, Berlin, 1995.

[85] Jamsa-Jounela, S. L., Vermasvuori, M., Enden, P., Haavisto, S.. A process monitoring system based on the Kohonen self-organizing maps[J]. Control Engineering Practice, 2003, 11: 83-92.

[86] Huang, R., Xi, L.. Residual life predictions for ball bearings based on self-organizing map and back propagation neural network methods[J]. Mechanical Systems and Signal Processing, 2007, 21(1): 193-207.

[87] 姚望舒，沈建强，李宁，等. BP 神经网络容噪性分析及其应用[J]. 小型微型计算机系统，2005，26(4): 631-634.

[88] Pearl, J.. Belief network revisited[J]. Artificial Intelligence, 1993, 59(1-2): 49-56.

[89] Russell G. A.. I can name that Bayesian network in two matrixes!, International Journal of Approximate Reasoning, 2010, 51(2): 167-178.

[90] Liu, Y., Li, S. Q.. Decision support for maintenance management using Bayesian networks[C]. International Conference on Wireless Communications, Networking and Mobile Computing, 2007, art. no. 4341175, 2007, 5708-5711.

[91] Donat, R., Leray, P., Bouillaut, L., Aknin, P.. A dynamic Bayesian network to represent discrete duration models[J]. Neurocomputing, 2010, 73(4-6): 570-577.

[92] Sheppard, J. W., Kaufman, M. A.. Bayesian diagnosis and prognosis using instrument uncertainty[C]. Proceedings of AUTOTESTCON, Sep 26-29 2005, Orlando, FL, United States, 2005: 417-423.

[93] Przytula, K. W., Choi, A.. Reasoning framework for diagnosis and prognosis[C]. Proceedings of 2007 IEEE Aerospace Conference, Mar 3-10 2007, Big Sky, MT, United States, art. no. 4161649, 2007.

[94] Gebraeel, N. Z., Lawley, M. A., Li, R., Ryan, J. K.. Residual-life distributions from component degradation signals: A Bayesian approach[J]. IIE Transaction, 2005, 37: 543-557.

[95] Dong, M., Yang, Z. B.. Dynamic Bayesian network based prognosis in machining processes[J]. Journal of Shanghai Jiao Tong University(Science), 2008, 13(3): 318-322.

[96] 杨志波，董明．动态贝叶斯网络在设备剩余寿命预测值的应用研究 [J]. 计算机集成制造系统，2007，13(9)：1811-1815.

[97] Gebraeel, N. Z.. Sensory-updated residual life distributions for components with exponential degradation patterns [J]. IEEE Transactions on Automation Science and Engineering, 2006, 3(4): 382-393.

[98] Gebraeel, N. Z., Pan, J.. Prognostic degradation models for computing and updating residual life distributions in a time-varying environment [J]. IEEE Transactions on Reliability, 2008, 57(4): 539-550.

[99] Gebraeel, N. Z., Elwany, A., Pan, J.. Residual life predictions in the absence of prior degradation knowledge [J]. IEEE Transactions on Reliability, 2009, 58(1): 106-116.

[100] Chakraborty, S., Gebraeel, N. Z., Lawley, M., etc.. Residual-life estimation for components with non-symmetric priors [J]. IIE Transactions, 2009, 41(4): 372-387.

[101] Engel, S. J, Gilmartin B. J., Bongort, K., etc.. Prognostics, the real issues involved predicting life remaining [C]. IEEE Aerospace Conference Proceedings, 2000: 457-470.

[102] Kwan, C., Zhang, X., Xu, R., etc.. A novel approach to fault diagnostics and prognostics [C]. Proceedings of the IEEE International Conference on Robotics & Automation, 2003: 604-609.

[103] Zhang, X., Xu, R., Kwan, C., etc.. An integrated approach to bearing fault diagnostics and prognostics [C]. Proceedings of the American Control Conference, 2005: 2750-2755.

[104] Chinnam, R. B., Baruah, P.. Autonomous diagnostics and prognostics through competitive learning driven HMM-based clustering [C]. Proceedings of the International Joint Conference on Neural Networks, 2003: 2466-2471.

[105] Chinnam, R. B., Baruah, P.. HMMs for diagnostics and prognostics in machining processes [J]. International Journal of Production Research, 2005, 43(6): 1275-1293.

[106] Camci, F., Chinnam, R. B.. Hierarchical HMMs for autonomous diagnostics and prognostics [C]. International Joint Conference on Neural Networks, 2006: 2445-2452.

[107] Camci, F., Chinnam, R. B.. Health-state estimation and prognostics in machining processes [J]. IEEE Transactions on Automation Science and Engineering, 2010, 7(3): 581-597.

[108] Zhou, Z. J., Hu, C. H., Xu, D. L., etc.. A model for real-time failure prognosis based on hidden Markov model and belief rule base [J]. European Journal of Operational Research, 2010, 207: 269-283.

[109] Gu, H. Y., Tseng, C. Y., Lee, L. S.. Isolated-utterance speech recognition using hid-

den Markov models with bounded state duration[J]. IEEE Transaction on Signal Processing, 1991,39(8):1743-1751.

[110] Falaschi,A.. Continuously variable transition probability HMM for speech recognition [C]. in Speech Recognition and Understanding, P. Laface and R. De Mori, Ed., Springer-Verlag Berlin Heidelberg,1992:125-130.

[111] Dong,M.,He,D.,Banerjee,P.,Keller,J.. Equipment health diagnosis and prognosis using hidden semi-Markov models[J]. International Journal of Advanced Manufacturing Technology,2006,30:738-749.

[112] Dong,M.,He,D.. Hidden semi-Markov model based methodology for multi-sensor equipment health diagnosis and prognosis [J]. European Journal of Operational Research,2007, 178(3):858-878.

[113] Dong,M.,He,D.. A segmental hidden semi-Markov model(HSMM)based diagnostics and prognostics framework and methodology [J]. Mechanical Systems and Signal Processing, 2007,21(5):2248-2266.

[114] Peng,Y.,Dong,M.. A prognosis method using age-dependent hidden semi-Markov model for equipment health prediction [J]. Mechanical System and Signal Processing,2010,25: 237-252.

[115] Goode,K. B.,Moore,J.,Roylance,B. J.. Plant machinery working life prediction method utilizing reliability and condition-monitoring data [J]. Proceedings of the Institution of Mechanical Engineers,2000,214(2):109-122.

[116] Yan,J.,Kog,M.,Lee,J.. A prognostic algorithm for machine performance assessment and its application [J]. Production Planning & Control,2004,15(8):796-801.

[117] Kumar,D.,Klefsjo,B.. Proportional hazards model:a review[J]. Reliability Engineering and System Safety,1994,44:177-188.

[118] Bebbington,M.,Lai,C. D.,Zitikis,R.. Reduction in mean residual life in the presence of a constant competing risk[J]. Stochastic Models in Business and Industry,2008,24(1):51-63.

[119] Wang,W.. A model to predict the residual life of rolling element bearings given monitored condition information to date[J]. IMA Journal of Management Mathematics,2002,13:3-16.

[120] Víctor,L.,Riquelme,M.,Balakrishnan,N.,Sanhueza,A.. Lifetime analysis based on the generalized Birnbaum-Saunders distribution[J]. Computational Statistics & Data Analysis, 2008,52:2079-2097.

[121] Cox,D. R.. Regression models and life-tables[J]. The Journal of Royal Statistic Society,1972,134:187-220.

[122] Liao,H.,Qiu,H.,Lee,J.,Lin,D.,Banjevic,D.. Jardine,A.,A predictive tool for

remaining useful life estimation of rotating machinery components[C]. Proceedings of the ASME International Design Engineering Technical Conferences and Computers and Information in Engineering Conference-DETC, Sep 24-28 2005, Long Beach, CA, United States, 2005, 1A: 509-515.

[123] Li, Z. G., Zhou, S., Choubey, S., Sievenpiper, C.. Failure event prediction using the Cox proportional hazard model driven by frequent failure signatures[J]. IIE Transactions, 2007, 39: 303-315.

[124] Volk, P. J.. Dynamic residual life estimation of industrial equipment based on failure intensity proportions [D]. Pretoria: University of Pretoria, 2001.

[125] Volk, P. J., Wnek, M., Zygmunt, M.. Utilising statistical residual life estimates of bearings to quantify the influence of preventive maintenance actions [J]. Mechanical Systems and Signal Processing, 2004, 18(4): 833-847.

[126] Banjevic, D., Jardine, A. K. S.. Calculation of reliability function and remaining useful life for a Markov failure time processes [J]. IMA Journal of Management Mathematics, 2006, 17 (2): 115-130.

[127] Wang, W., Scarf, P. A., Smith, M. A. J.. On the application of a model of condition-based maintenance [J]. The Journal of the Operational Research Society, 2000, 51(11): 1218-1227.

[128] Xie, N. M., Liu, S. F.. Discrete grey forecasting model and its optimization[J]. Applied Mathematical Modelling, 2009, 33(2): 1173-1186.

[129] Huang, Y. P., Huang, C. C., Hung, C. H.. Determination of the preferred fuzzy variables and applications to the prediction control by the grey modeling[C]. The Second National Conference on Fuzzy Theory and Application, Taipei, Taiwan: 1994: 406-409.

[130] 罗佑新，张龙庭，李敏．灰色系统理论及其在机械工程中的应用[J]. 2001, 9.

[131] 陈举华，郭毅之．模型优化方法在小子样机械系统故障预测中的应用[J]. 中国机械工程，2002, 13(19): 658-660.

[132] Gu, J., Bilal, M., Pecht, M.. Grey prediction method used in failure prognostics for electronics, http://www.prognostics.umd.edu/PHM_Website_new/ PHM_grey_prediction.pdf.

[133] Lu, S., Lu, H., Kolarik, W.. Multivariate performance reliability prediction in real-time [J]. Reliability Engineering & System Safety, 2001, 72(1): 39-45.

[134] Sun, J., Zuo, H., Wang, W., Pecht, M.. Application of a state space modeling to system prognostics based on a health index for condition-based maintenance[J]. Mechanical Systems and Signal Processing, 2012, 28: 585-596.

[135] Wang, W., Christer, A.. Towards a general condition based maintenance model for a sto-

chastic dynamic system [J]. Journal of the Operational Research Society,2000,51(2):145-155.

[136] Wang,W. ,Zhang,W.. A model to predict the residual life of aircraft engines based upon oil analysis data [J]. Naval Research Logistics,2005,52(3):276-284.

[137] Niu,G. ,Yang,B.. Intelligent condition monitoring and prognostics system based on data fusion strategy [J]. Expert Systems with Applications,2010,37(12):8831-8840.

[138] Caesarendra,W. ,Widodo,A. ,Thom,P. H. ,etc.. Combined probability approach and indirect data-driven method for bearing degradation prognostics [J]. IEEE Transaction on reliability,2011,60(1):14-20.

[139] Reichard,K. M. ,Dyke,M. V. ,Maynard,K.. Application of sensor fusion and signal classification techniques in a distributed machinery condition monitoring system [C]. Proceedings of SPIE-The International Society for Optical Engineering,2000:329-336.

[140] Wei,M. ,Chen,M. ,Zhou,D. ,Wang,W.. Remaining useful life prediction using a stochastic filtering model with multi-sensor information fusion [C]. Prognostics and System Health Management Conference(PHM-Shenzhen),2011:1-6.

[141] Wei, M. H. , Chen, M. Y. , Zhou, D. H.. Multi-Sensor Information Based Remaining Useful Life Prediction with Anticipated Performance [J]. IEEE Transactions on reliability,2013,62(1):183-198.

[142] El-Koujoka,M. ,Benammar,M. ,Meskin,N. ,etc.. Multiple sensor fault diagnosis by evolving data-driven approach [J]. Information Sciences,2013,Article in Press.

[143] Satish,B. ,Sarma,N. D. R.. A fuzzy BP approach for diagnosis and prognosis of bearing faults in induction motors[C]. IEEE Power Engineering Society General Meeting,Jun 12-16 2005,San Francisco,CA,United States,2005,3:2291-2294.

[144] Xue,G. X. ,Xiao,L. C. ,Bie,M. H. ,Lu,S. W.. Fault prediction of boilers with fuzzy mathematics and RBF neural network[C]. Proceedings of the International Conference on Communications,Circuits and Systems,May 27-30 2005,Hong Kong,China,2005,2:1012-1016.

[145] Kothamasu, R. , Huang, S. H.. Adaptive Mamdani fuzzy model for condition-based maintenance[J]. Fuzzy Sets and Systems,2007,158:2715-2733.

[146] Chen,M. Y.. Uncertainty analysis and grey modeling[C]. Proceedings of the 1st International Symposium on Uncertainty Modeling Analysis,1990,469-473.

[147] Dong, Y. L. , Gu, Y. J. , Yang, K.. Zhang, W. K.. A combining condition prediction model and its application in power plant[C]. Proceedings of the International Conference on Machine Learning and Cybernetics,Aug 26-29 2004,Shanghai,China,2004,6:3474-3478.

[148] Shetty,P. ,Mylaraswamy,D. ,Ekambaram,T.. A hybrid prognostic model formulation and health estimation of auxiliary power units[J]. Journal of Engineering for Gas Turbines and

Power, art. no. 021601, 2008. 130(2).

[149] Mohanty, S., Chattopadhyay, A., Peralta, P., Dras, S., Willhauck, C.. Fatigue life prediction using multivariate Gaussian process[C]. Collection of Technical Papers AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference, Apr 7-10 2008, Schaumburg, IL, United States, art. no. 2008-1837.

[150] Zhao, F. Q., Tian, Z. G., Zeng, Y.. A stochastic collocation approach for efficient integrated gear health prognosis [J]. Mechanical Systems and Signal Processing, 2013, 39: 372-387.

[151] Liu, D. T., Peng, Y., Li, J. B., Peng, X. Y.. Multiple optimized online support vector regression for adaptive time series prediction [J]. Measurement, 2013, 46: 2391-2404.

[152] Hua, C., Zhang, Q., Xu, G. H., etc.. Performance reliability estimation method based on adaptive failure threshold [J]. Mechanical Systems and Signal Processing, 2013, 36: 505-519.

[153] 李凌均，张周锁，何正嘉．基于支持向量机的机械设备状态趋势预测研究[J]．西安交通大学学报，2004，38(3)：230-233.

[154] 杨俊燕，张优云，赵荣珍．支持向量机在机械设备振动信号趋势分析中的应用[J]．西安交通大学学报，2005，39(9)：950-953.

[155] Manatos, A., Koutras, V. P., Platis, A. N.. Dependability and performance stochastic modelling of a two-unit repairable production system with preventive maintenance[J]. International Journal of Production Research, 2016, 54(21): 6395-6415.

[156] 奚立峰，周晓军，李杰．有限区间内设备顺序预防性维护策略研究[J]．计算机集成制造系统，2005，10：117-120.

[157] Chen, Y., Cowling, P., Polack, F., Remde, S., Mourdjis, P.. Dynamic optimisation of preventative and corrective maintenance schedules for a large scale urban drainage system[J]. European Journal of Operational Research, 2017, 257(2): 494-510.

[158] Yang, Z., Djurdjanovic, D., Ni, J.. Maintenance scheduling in manufacturing systems based on predicted machine degradation [J]. Journal of Intelligent Manufacturing, 2008, 19(1): 87-98.

[159] Pedregal, D. J., Carnero, M. C.. State space models for condition monitoring: a case study [J]. Reliability Engineering and System Safety, 2006, 91(2): 171-180.

[160] Lu, S., Tu, Y. C., Lu, H.. Predictive condition-based maintenance for continuously deteriorating systems [J]. Quality and Reliability Engineering International, 2007, 23(1): 71-81.

[161] Wu, F., Wang, T., Lee, J.. An online adaptive condition-based maintenance method for mechanical systems [J]. Mechanical Systems and Signal Processing, 2010, 24(8): 2985-2995.

[162] Jafari, L., Makis, V.. Optimal lot-sizing and maintenance policy for a partially observable production system [J]. Computers & Industrial Engineering, 2016, 93: 88-98.

[163] Tran, V. T., Yang, B. S.. An intelligent condition-based maintenance platform for rotating machinery [J]. Expert Systems with Applications, 2012, 39: 2977-2988.

[164] Jafari, L., Makis, V.. Joint optimization of lot-sizing and maintenance policy for a partially observable two-unit system [J]. International Journal of Advanced Manufacturing Technology, 2016, 87(5-8): 1621-1639.

[165] Ghasemi, A., Yacout, S., Ouali, M. S.. Optimal condition based maintenance with imperfect information and the proportional hazards model [J]. International Journal of Production Research, 2007, 45(4): 989-1012.

[166] Wang, B., Hussin, B., Jefferis, T.. A case study of condition based maintenance modelling based upon the oil analysis data of marine diesel engines using stochastic filtering [J]. International Journal of Production Economics, 2012, 136: 84-92.

[167] Wang, Q. F., Gao, J. J.. Research and application of risk and condition based maintenance task optimization technology in an oil transfer station [J]. Journal of Loss Prevention in the Process Industries, 2012, 25: 1018-1027.

[168] Tian, Z. G., Jin, T. D., Wu, B. R., Ding. F. F.. Condition based maintenance optimization for wind power generation systems under continuous monitoring [J]. Renewable Energy, 2011, 36: 1502-1509.

[169] Cui, W. W., Lu, Z. Q., Zhou, B. H., Li, C., Han, X. L.. A hybrid genetic algorithm for non-permutation flow shop scheduling problems with unavailability constraints [J]. International Journal of Computer Integrated Manufacturing, January 6, 2016, pp. 1-18, Article in Press.

[170] Wang, W. B.. A simulation-based multivariate Bayesian control chart for real time condition-based maintenance of complex systems [J]. European Journal of Operational Research, 2012, 218: 726-734.

[171] Elhdad, R., Chilamkurti, N., Torabi, T.. An ontology-based framework for process monitoring and maintenance in petroleum plant [J]. Journal of Loss Prevention in the Process Industries, 2013, 26: 104-116.

[172] Cui, W. W., Lu, Z. Q.. Minimizing the makespan on a single machine with flexible maintenances and jobs' release dates [J]. Computers & Operations Research, 2017, 80: 11-22.

[173] Guo, C. M., Wang, W. B., Guo, B., Si, X. S.. A maintenance optimization model for mission-oriented systems based on Wiener degradation [J]. Reliability Engineering and System Safety, 2013, 111: 183-194.

[174] Zhao, X. F., Qian, C. H., Nakagawa, T.. Optimal policies for cumulative damage models with maintenance last and first [J]. Reliability Engineering and System Safety, 2013, 110: 50-59.

[175] Lopez-Campos, M. A., Marquez, A. C., Fernandez, J. F.. Modelling using UML and BPMN the integration of open reliability, maintenance and condition monitoring management systems: An application in an electric transformer system [J]. Computers in Industry, 2013, 64: 524-542.

[176] Wang, L., Chu, J., Mao, W.. A condition-based order-replacement policy for a single-unit system[J]. Applied Mathematical Modelling, 2008, 32(11): 2274-2289.

[177] Wang, L., Chu, J., Mao, W.. A condition-based replacement and spare provisioning policy for deteriorating systems with uncertain deterioration to failure [J]. European Journal of Operational Research, 2009, 194(1): 184-205.

[178] Wang, L., Chu, J., Mao, W.. An optimum condition-based replacement and spare provisioning policy based on Markov chains [J]. Journal of Quality in Maintenance Engineering, 2008, 14(4): 387-401.

[179] Cheng, T. J., Pandey, M. D., van der Weide, J. A. M.. The probability distribution of maintenance cost of a system affected by the gamma process of degradation: Finite time solution [J]. Reliability Engineering & System Safety, 2012, 108: 65-76.

[180] Xia, T. B., Xi, L. F., Zhou, X. J., Du, S. C.. Modeling and optimizing maintenance schedule for energy systems subject to degradation [J]. Computers & Industrial Engineering, 2012, 63(3): 607-614.

[181] Chulsoon, P., Dughee, M., Namchul, D., Bae, S. M.. A predictive maintenance approach based on real-time internal parameter monitoring [J]. International Journal of Advanced Manufacturing Technology, 2016, 85(1-4): 623-632.

[182] Barbera, F., Schneider, H., Watson, E.. A condition based maintenance model for a two-unit series system [J]. European Journal of Operational Research, 1999, 116(2): 281-290.

[183] Shahanaghi, K., Babaei, H., Bakhsha, A., etc... A new condition based maintenance model with random improvements on the system after maintenance actions: optimizing by Monte Carlo simulation [J]. World Journal of Modelling and Simulation, 2008, 4(3): 230-236.

[184] Aven, T.. Condition based replacement policies-a counting process approach [J]. Reliability Engineering and System Safety, 1996, 51(3): 275-281.

[185] Wang, W.. A model to determine the optimal critical level and the monitoring intervals in condition-based maintenance [J]. International Journal of Production Research, 2000, 38(6): 1425-1436.

[186] Farnoosh Naderkhani, Z. G., Makis, V.. Optimal condition-based maintenance policy for a partially observable system with two sampling intervals [J]. International Journal of Advanced Manufacturing Technology, 2015, 78(5-8): 795-805.

[187] Maillart,L. M.. Maintenance policies for systems with condition monitoring and obvious failures [J]. IIE Transactions,2006,38(6):463-475.

[188] Castanier,B.,Berenguer,C.,Grall,A.. A sequential condition-based repair policy with non-periodic inspections for a system subject to continuous wear [J]. Applied Stochastic Models in Business and Industry,2003,19(4):327-347.

[189] Castanier,B.,Berenguer,C.,Grall,A.. A condition-based maintenance policy with non-periodic inspections for a two-unit series system [J]. Reliability Engineering and System Safety,2005,87(1):109-120.

[190] Dieulle,L.,Berenguer,C.,Grall,A.,etc.. Sequential condition-based maintenance scheduling for a deteriorating system [J]. European Journal of Operational Research,2003,150(2):451-461.

[191] 胡家文,蒋祖华,韩李杰. 工况时变下设备预防维护策略[J]. 上海交通大学学报,2016,05:736-749.

[192] Deloux,E.,Castanier,B.,Berenguer,C.. Predictive maintenance policy for a gradually deteriorating system subject to stress [J]. Reliability Engineering and System Safety,2009,94(2):418-431.

[193] Zhao,X.,Fouladirad,M.,Berenguer,C.,etc.. Condition-based inspectiont policies for non-monotone deteriorating systems with environmental covariates [J]. Reliability Engineering and System Safety,2010,95:921-934.

[194] Nakagawa,T.,Ito,K.. Optimal maintenance policies for a system with multi-echelon risks [J]. IEEE Transactions on Systems,Man,and Cybernetics-Part A:Systems and Humans,2008,38(2):461-469.

[195] Liao,H.,Elsayed,E. A.,Chan,L. Y.. Maintenance of continuously monitored degradation systems [J]. European Journal of Operational Research,2006,175(2):821-835.

[196] Kaiser,K. A.,Gebraeel,N. Z.. Predictive maintenance management using sensor-based degradation models [J]. IEEE Transactions on Systems,Man,and Cybernetics-Part A:Systems and Humans,2009,39(4):840-849.

[197] Nevesa,M. L.,Santiago,L. P.,Carlos,A.,Maia,C. A.. A condition-based maintenance policy and input parameters estimation for deteriorating systems under periodic inspection [J]. Computers & Industrial Engineering,2011,61:503-511.

[198] Kahrobaee,S.,Asgarpoor,S.. A hybrid analytical-simulation approach for maintenance optimization of deteriorating equipment:Case study of wind turbines [J]. Electric Power Systems Research,2013,104:80-86.

[199] Len,M. D.,Tan,C. M.. Optimal maintenance strategy of deteriorating system under

imperfect maintenance and inspection using mixed inspection scheduling [J]. Reliability Engineering and System Safety, 2013, 113: 21-29.

[200] Park, C. W., Lee, H. S.. A multi-class closed queuing maintenance network model with a parts inventory system [J]. Computers & Operations Research, 2011, 38(11): 1584-1595.

[201] De Smidt-Destombes, K. S., Van der Heijden, M. C., Van Harten, A.. On the interaction between maintenance, spare part inventories and repair capacity for a k-out-of-N system with wear-out [J]. European Journal of Operational Research, 2006, 174(1): 182-200.

[202] De Smidt-Destombes, K. S., van der Heijden, M. C., van Harten, A.. Joint optimisation of spare part inventory, maintenance frequency and repair capacity for k-out-of-N systems[J]. International Journal of Production Economics, 2009, 118(1): 260-268.

[203] Van Jaarsveld, W., Dekker, R.. Spare parts stock control for redundant systems using reliability centered maintenance data [J]. Reliability Engineering & System Safety, 2011, 96(11): 1576-1586.

[204] Basten, R. J. I., van der Heijden, M. C., Schutten, J. M. J.. Joint optimization of level of repair analysis and spare parts stocks [J]. European Journal of Operational Research, 2012, 222(3): 474-483.

[205] Huynh, K. T., Castro, I. T., Barros, A., Bérenguer, C.. Modeling age-based maintenance strategies with minimal repairs for systems subject to competing failure modes due to degradation and shocks [J]. European Journal of Operational Research, 2012, 218(1): 140-151.

[206] Wang, W. B.. A joint spare part and maintenance inspection optimisation model using the delay-time concept [J]. Reliability Engineering and System Safety, 2011, 96(11): 1535-1541.

[207] Wang, W. B.. A stochastic model for joint spare parts inventory and planned maintenance optimization [J]. European Journal of Operational Research, 2012, 216(1): 127-139.

[208] Rausch, M., Liao, H. T.. Joint Production and Spare Part Inventory Control Strategy Driven by Condition Based Maintenance [J]. IEEE Transaction on Reliability, 2010, 59(3): 507-516.

[209] Elwany, A. H., Gebraeel, N. Z.. Sensor-driven prognostic models for equipment replacement and spare parts inventory [J]. IIE Transactions, 2008, 40: 629-639.

[210] Lin, X., Basten, R. J. I., Kranenburg, A. A., Van Houtum, G. J.. Condition based spare parts supply, Working paper. 2012.

[211] Louit, D., Pascual, R., Banjevic, D., Jardine, A. K. S.. Condition-based spares ordering for critical components [J]. Mechanical Systems and Signal Processing, 2011, 25: 1837-1848.

[212] Li, R., K. Ryan, J. K.. A Bayesian Inventory Model Using Real-Time Condition Monitoring Information [D]. Singapore Management University. 2008.

[213] Nguyen,T. P. K. ,Yeung,T. G. ,Castanier,B.. Optimal maintenance and replacement decisions under technological change with consideration of spare parts inventories [J]. International Journal of Production Economics,2013,143:472-477.

[214] Van Horenbeek A,Bure J,Cattrysse D,Pintelon L,Vansteenwegen P.. Joint maintenance and inventory optimization systems:A review [J]. International Journal of Production Economics,2013,143:499-508.

[215] Rabiner,L. R.. A tutorial on hidden Markov models and selected applications in speech recognition [J]. Proceedings of the IEEE,1989,77:257-286.

[216] Baruah,P. ,Chinnam,R. B.. HMMs for diagnostics and prognostics in machining processes[J]. International Journal of Production Research,2003,43(6):1275-1293.

[217] Ljolie,A. ,Levinson,S. E.. Development of an acoustic-phonetic hidden Markov model for continuous speech recognition [J]. IEEE Transaction on Signal Processing,1991,39:29-39.

[218] Ostendorf,M.. Stochastic segment model for phoneme-based continuous speech recognition[J]. IEEE Transactions on Acoustics,Speech,and Signal Processing,1989,37:1857-1869.

[219] Kannan,A. ,Ostendorf,M.. Comparison of trajectory and mixture modeling in segment-based word recognition[C]. Proceedings of the IEEE International Conference on Acoustics,Speech and Signal Processing,Minneapolis,MN,1993:327-330.

[220] Bunks,C. ,McCarthy,D. ,Al-Ani,T.. Condition-based maintenance of machines using hidden Markov models[J]. Mechanical Systems and Signal Processing,2000,14(4):597-612.

[221] Wang,L. ,Mehrabi,M. G. ,Kannatey-Asibu,E.. Hidden Markov model-based tool wear monitoring in machining [J]. ASME Journal of Manufacturing Science and Engineering,2002,124:651-658.

[222] Atlas,L. ,Ostendorf,M. ,Bernard,G. D.. Hidden Markov models for monitoring machining tool-wear[C]. Proceedings of the IEEE International Conference on Acoustics,Speech and Signal Processing,Istanbul,Turkey,2000,6:3887-3890.

[223] Ertunc,H. M. ,Loparo,K. A.. A decision fusion algorithm for tool wear condition monitoring in drilling[J]. International Journal of Machine Tools and Manufacture,2001,41:1347-1362.

[224] Ertunc,H. M. ,Loparo,K. A. ,Ocak,H.. Tool wear condition monitoring in drilling operations using hidden Markov models(HMMs)[J]. International Journal of Machine Tools and Manufacture,2001,41:1363-1384.

[225] Begg,C. D. ,Merdes,T. ,Byington,C. ,Maynard,K.. Dynamic modeling for mechanical diagnostics and prognostics[C]. Proceedings of the Maintenance and Reliability Conference,Tennessee,1999:2201-2213.

[226] Roemer, M. J., Kacprzynski, G. J.. Advanced diagnostics and prognostics for gas turbine engine risk assessment[C]. Proceedings of the IEEE International Conference on Aerospace Conference, Big Sky, Montana, 2000: 345-354.

[227] Roemer, M. J., Nwadiogbu, E. O., Bloor, G.. Development of diagnostic and prognostic technologies for aerospace health management applications [C]. in: Proceedings of the IEEE International Conference on Aerospace Conference, Big Sky, Montana, 2001: 63139-63147.

[228] Baum, L. E., Egon, J. A.. An inequality with applications to statistical estimation for probabilistic functions of a Markov process and to a model for ecology[J]. Bulletin of the American Mathematical Society, 1967, 73: 360-363.

[229] Yang. S. Z.. Hidden semi-Markov models[J]. Artificial Intelligence, 2010, 174: 215-243.

[230] Viterbi, A. J.. Error bounds for convolutional codes and an asymptotically optimal decoding algorithm[J]. IEEE Transaction on Information Theory, 1967, 13: 260-269.

[231] Dempster, A. P., Laird, N. M., Rubin, D. B.. Maximum likelihood from incomplete data via the EM algorithm[J]. Journal of the Royal Statistical Society, 1977, 39: 1-38.

[232] Burrus, C. S., Gopinath, R. A., Guo, H. T.. Introduction to Wavelets and Wavelet Transforms: A Primer [M]. Prentice Hall, N. J., USA, 1997.

[233] Tang, Z. H., Wang R. Q.. The research of definition and feature on Dirac delta function [J]. Journal of Lzhou Vocational & Technical College, 2009, 9(2): 68-76.

[234] Zheng, X.. All opportunity—Iriggered replacement policy for multiple-unit systems [J]. IEEE Tran. Reliab, 1995, 44(4): 648-652.

[235] Legat, V., Zaludora, A. H., Cervenka, V.. Contribution to optimization of preventive replacement[J]. Reliab. Engg. Syst. Safety, 1996, 51(3): 259-266.

[236] Wang, K. S., Tsai, Y. T., Lill, C. H.. Study of replacement policy for components in a mechanical system[J]. Reliab. Engg. Syst. Safety, 1997, 58(3): 191-199.

[237] Chan, J., Shaw, L.. Modeling repairable systems with failure rates that depend On age and maintenance[J]. IEEE Trans Reliab, 1993, 42(4): 566-571.

[238] Martorell, S., Munoz, A., Serradell, V.. Age-dependent models for evaluating risks and costs of surveillance and maintenance of systems[J]. IEEE Tran Reliab, 1996, 45(3): 433-441.

[239] Martorell, S., Sanchez, A., Serradell, V.. Age-dependent reliability model considering effects of maintenance and working conditions[J]. Reliab Engg Syst Safety, 1996, 64(1): 19-31.

[240] Nakagawa. T.. Modified periodic replacement with minimal repair at failure[J]. IEEE Transactions on Reliability, 1981, 30: 165-168.

[241] Nakagawa, T.. Optimal policy of continuous and discrete replacement with minimal repair at failure[J]. Naval Research Logistics, 1984, 31(4): 543-550.

[242] Sheu, S., Grifith, W. S., Nakagawa, T.. Extended optimal replacement model with random minimal repair costs[J]. European Journal of Operational Research, 1995, 85(3): 636-649.

[243] Wang, H., Pham, H.. Some maintenance models and availability with imperfect maintenance in production systems[J]. Annals of Operations Research, 1999, 91: 305-318.

[244] Amari, S., Fulton, W.. Bounds on optimal replacement time of age replacement policy, In Proceedings of Annual Reliability and Maintainability Symposium on Product Quality and Integrity[J]. Tampa, Florida, USA, 2003: 417-422.

[245] Nakagawa, T.. Periodic and sequential preventive maintenance policies[J]. Journal of Applied Probability, 1986, 23(2): 536-542.

[246] Liu, X., Makis, V., Jardine, A. K.. A replacement model with overhauls and repairs [J]. Naval Research Logistics, 1995, 42: 1063-1079.

[247] Nakagawa, T.. A summary of imperfect maintenance policies with minimal repair [J]. RAIRO: Research and Operation Annal, 1980, 14: 249-255.

[248] Tango, T.. Extended block replacement policy with used items[J]. Journal of Applied Probability, 1978, 15: 560-572.

[249] Gertsbakh, I. B.. Optimal group preventive maintenance of a system with observable state parameter[J]. Advances in Applied Probability, 1984, 16: 923-925.

[250] Assaf, D., Shanthikumar, J. G.. Optimal group maintenance policies with continuous and periodic inspections[J]. Management Science, 1987, 33: 1440-1450.

[251] Nakagawa, T.. Sequential imperfect preventive maintenance policies[J]. IEEE Transactions on Reliability, 1988, 37(3): 295-298.

[252] Maillart, L. M., Pollock, S. M.. Cost-Optimal Condition—Monitoring for Predictive Maintenance of 2-Phase Systems[J]. IEEE Transactions on Reliability, 2002, 51(3): 322-330.

[253] Lie, C. H., Chun, Y. H.. An algorithm for preventive maintenance policy[J]. IEEE Transactions on Reliability, 1986, 35(1): 71-75.

[254] Grail, A., Berenguer, C., Dieulle, L. A.. Condition-based maintenance policy for stochastically deteriorating systems[J]. Reliability Engineering and System Safety, 2002, 76(1): 167-180.

[255] Chen, D., Trivedi, K. S.. Closed form analytical results for condition-based maintenance[J]. Reliability Engineering and System Safety, 2007, 76(1): 43-51.

[256] Monga, A., Zuo, M. J., Toogood, R.. Reliability based design of systems considering

preventive maintenance and minimal repair, International Journal of Reliability[J]. Quality and Safety Engineering, 1997, 4(1): 55-71.

[257] Badia, F. G., Berrade, M. D., Campos, C. A.. Optimal inspection and preventive maintenance of units with revealed and unrevealed failures[J]. Reliability Engineering and System Safety, 2008, 78(2): 157-163.

[258] Soro, I. W., Nourelfath, M., Aït-Kadi, D.. Performance evaluation of multi-state degraded systems with minimal repairs and imperfect preventive maintenance[J]. Reliability Engineering and System Safety, 2010, 95(2): 65-69.

[259] Barlow, R. E., Proshan, F.. Mathematical Theory of Reliability[J]. IEEE Transactions on Reliability, 1984, 33(1): 16-20.

[260] Drinkwater, R. W., Hastings, N. V. J.. An economic replacement model[J]. Operational Research Quarterly, 1967, 18: 121-138.

[261] Dimitrakos, T. D., Kyriakidis, E. G.. An improved algorithm for the computation of the optimal repair/replacement policy under general repairs[J]. European Journal of Operation Research, 2007, 182(2): 775-782.

[262] Chien, Y. H., Chang, C. C., Sheu, S. H.. Optimal periodical time for preventive replacement based on a cumulative repair-cost limit and random lead time[J]. Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability, 2010, 223(4): 333-345.

[263] Beichelt, F.. A replacement policy based on limits for the repair cost rate[J]. IEEE Transactions on Reliability, 1982, 31(4): 401-412.

[264] Nakagawa, T., Osaki, S.. The optimum repair limit replacement policies[J]. Operational Research Quarterly, 1974(25): 311-317.

[265] Dohi, T., Matsushima, N., Kaio, N.. Non parametric repair-limit replacement policies with imperfect repair[J]. European Journal of Operational Research, 1997, 96(2): 260-273.

[266] Nguyen, D. C., Murthy, D. N. P.. A note of the repair limit replacement policy[J]. Journal of Operational Research Society, 1980, 31: 1103-1104.

[267] Haneveld, W. K., Teunter, R. H.. Optimal Provisioning strategies for slow moving spare parts with small lead times[J]. Journal of the Operational Research Society, 1997, 48: 184-194.

[268] Jeffery, K. C., Theodore, P. L.. Computing small-fleet aircraft avaiabilities including redundancy and spares[J]. Computer&Operations Research, 2002, 29(5): 529-540.

[269] Mitchel, J. C.. Multi-items inventory systems with a service objective. Operations Research[J]. 1998, 36: 747-755.

[270] Cohen, M. A., Klemdorfer, P. R., Lee, H. L.. Multi-items service constrained (s, S)

policies for spare parts logistics systems[J]. Naval Research Logistics,1992,3:561-577.

[271] HOPP,W. H. ,Spearman,M. L. ,Zhang,R. Q.. Easily implemental inventory control policies[J]. Operations Research,1997,45:327-340.

[272] Thonemarm,U. W. ,Brown,A. O. ,Hausman,W. H.. Easy quantification of improved spare parts inventory policies[J]. Management Science,2002,48:1213-1222.

[273] Wu,H. X. ,Yu,Z. H. ,W,Y.. Real-time FDM machine condition monitoring and diagnosis based on acoustic emission and hidden semi-Markov model [J]. International Journal of Advanced Manufacturing Technology,October 7,2016:1-10,Article in Press.

[274] Tang,D. Y. ,Makis,V. ,Jafari,L. ,Yu,J. S.. Optimal maintenance policy and residual life estimation for a slowly degrading system subject to condition monitoring [J]. Reliability Engineering and System Safety,2015,134:198-207.

[275] Khaleghei,A. ,Makis,V.. Reliability estimation of a system subject to condition monitoring with two dependent failure modes [J]. IIE Transactions,2016,48(11):1058-1071.